

# **SW pro modelování volumetrických MR obrazových dat mozkových metastáz**

SW for modeling of MR volumetric image data of brain metastases

**Bc. Kateřina Szulová**

**Diplomová práce**

**Vedoucí práce: Ing. Jan Kubíček, Ph.D.**

**Ostrava 2021**

## **Abstrakt**

Tato diplomová práce se zaměřuje na problematiku nádorových onemocnění mozku a vývojem softwaru pro modelování volumetrických MR dat mozkových metastáz. Rešeršní část se zabývá základy anatomie mozku, principem magnetické rezonance, rozdělením typů nádorů a popisem segmentačních metod, které jsou využity v praktické části této práce.

Praktická část je zaměřena na tvorbu algoritmu pro automatickou segmentaci a volumetrii mozkových nádorů. Předzpracováním dat se zvýrazní objekt zájmu, čímž se usnadní jeho segmentace. Poté je využit algoritmus pro segmentaci tumoru, který oddělí tumor od okolní tkáně, která není v popředí zájmu, a z takto upravených dat se vypočte objem k upřesnění velikosti tumoru. Na základě těchto metod vznikne intuitivní software na automatickou segmentaci mozkových tumorů na datech magnetické rezonance pro klinické účely.

## **Klíčová slova**

mozek, nádorové onemocnění, magnetická rezonance, segmentace, aktivní kontury

## **Abstract**

This diploma thesis focuses on brain cancer problematics and on the development of SW for modeling MR volumetric image data of brain metastases. The theoretical part includes the basics from anatomy, principles of magnetic resonance, division of tumor types and description of segmentation methods, which are used in the practical part of this thesis.

The practical part aims at the creation of algorithm for automatic segmentation and volumetry of brain tumors. By data preprocessing is highlighted the object of interest and simplify its segmentation. After that the segmentation algorithm is created to separate the tumor from surrounding tissue, which is not at the region of interest. From acquired image is possible to calculate volume to specify the size of tumor. Based on these methods could be created an intuitive software for automatic segmentation of brain tumors on MR data for clinical purposes.

## **Keywords**

brain, cancer, magnetic resonance, segmentation, active contours

## **Poděkování**

Tímto bych ráda poděkovala panu Ing. Janu Kubíčkovi, Ph.D. za trpělivost, věnovaný čas a drahocenné rady, které mi pomohly k vypracování této diplomové práce. V neposlední řadě tímto děkuji své rodině a mému snoubenci za podporu při vypracovávání této práce.

## Obsah

|   |           |
|---|-----------|
| Seznam zkratk .....   | 7         |
| Seznam ilustrací .....  | 8         |
| Seznam tabulek .....  | 11        |
| Úvod .....  | 12        |
| <b>1 TEORETICKÝ ROZBOR .....</b>                                      | <b>13</b> |
| 1.1 Anatomie mozku .....  | 13        |
| 1.2 Magnetická resonance .....  | 15        |
| 1.2.1 Základní sekvence .....   | 16        |
| 1.2.2 MRI mozku .....   | 18        |
| 1.2.3 Sekvence .....  | 19        |
| 1.2.4 Průběh vyšetření .....  | 22        |
| 1.3 Nádory mozku .....  | 23        |
| 1.3.1 Astrocytomy .....   | 23        |
| 1.3.2 Oligodendrogliom .....  | 25        |
| 1.3.3 Ependymomy .....  | 26        |
| 1.3.4 Neuronální nádory .....   | 27        |
| 1.3.5 Nádory mening .....   | 28        |
| 1.3.6 Nádorové metastázy .....  | 28        |
| 1.4 Segmentace obrazu .....   | 29        |
| 1.4.1 Metody založené na principu detekce hran .....                  | 30        |
| 1.4.2 Metody založené na oblasti v obraze .....                       | 32        |
| 1.4.3 Metody statické .....   | 33        |
| 1.5 Metody aktivních kontur .....                                     | 34        |
| 1.5.1 Aktivní kontury využívající gradient .....                      | 34        |
| 1.5.2 Aktivní kontury bez využití gradientu .....                     | 36        |
| <b>2 PRAKTICKÁ ČÁST .....</b>   | <b>38</b> |
| 2.1 Automatický model pro detekci a extrakci mozkových metastáz ..... | 38        |
| 2.1.1 Analýza dat .....   | 38        |
| 2.1.2 Předzpracování obrazu .....                                     | 40        |
| 2.1.3 Implementace aktivních kontur v prostředí MATLAB .....          | 42        |
| 2.1.4 Průběh segmentačního algoritmu .....                            | 44        |
| 2.1.5 Geneze volumetrického modelu mozkových tumorů .....             | 51        |

|       |   |           |
|-------|---|-----------|
| 2.2   | Evaluace a validace segmentačního modelu .....                          | 52        |
| 2.2.1 | Index korelace.....   | 54        |
| 2.2.2 | SSIM.....   | 57        |
| 2.3   | Software pro automatickou detekci a kvantifikaci mozkových nádorů ..... | 61        |
|       | <b>Závěr .....</b>  | <b>64</b> |
|       | <b>Zdroje .....</b>   | <b>65</b> |

## Seznam zkratek

3 D – trojrozměrný

CNS – centrální nervový systém

CP – Circular Polarized

CT – počítačová tomografie

E – energie (J)

KL – kontrastní látka

MR – magnetická rezonance

MRI – zobrazování magnetickou rezonancí

PC – počítač

PD – proton denzní

SE – spinové echo

T – Tesla, jednotka magnetické indukce

T1 – podélná relaxace

T1 – příčná relaxace

TE – time to echo

TR – time to repeat

% - procenta

## Seznam ilustrací

- Obr. č. 1:** Anatomie mozku, str. 14
- Obr. č. 2:** Precesní pohyb, str. 16
- Obr. č. 3:** Porovnání PD, T1 a T2 váženého obrazu u MRI mozku, str. 17
- Obr. č. 4:** Magnetická resonance Siemens Avanto 1,5T, str.18
- Obr. č. 5:** Sekvence T1 SE, str. 19
- Obr. č. 6:** Sekvence T1 IR, str. 19
- Obr. č. 7:** Sekvence T2 TSE, str. 20
- Obr. č. 8:** Sekvence FLAIR, str. 20
- Obr. č. 9:** Sekvence T1 + KL, str. 21
- Obr. č. 10:** Sekvence T2 TSE 3D, str. 21
- Obr. č. 11:** Uložení pacienta s CP hlavovou cívkou značky Siemens, str. 22
- Obr. č. 12:** Astrocytom grade I v zadní jámě lební, A: CT po KL, B: MR obraz T1 po KL, str. 24
- Obr. č. 13:** Astrocytom grade II v temporálním laloku vlevo, A: CT po KL, B: MR obraz T2 po KL, str. 24
- Obr. č. 14:** Astrocytom grade III, A: CT obraz po KL, B: MR obraz T1 po KL, str. 25
- Obr. č. 15:** Glioblastom grade IV parietálního laloku, A: CT obraz po KL, B: MR obraz T1 po KL, str. 25
- Obr. č. 16:** Oligodendrogliom bazálních ganglií, A: nativní CT, B: MR obraz T2, str. 26
- Obr. č. 17:** Ependymom III. Komory, A: MR nativní T1, B: MR obraz T2 po KL, str. 26
- Obr. č. 18:** Gangliom mozečku MR (FLAIR) T2 obraz, str. 27
- Obr. č. 19:** Neurocytom MR T2 obraz, str. 27
- Obr. č. 20:** Neuronální tumor projevující se jako koloidní cysta MR T1 obraz, str. 27
- Obr. č. 21:** Meningeom umístěný vedle hypofýzy, A: CT po KL, B: MR T1 obraz, str. 28
- Obr. č. 22:** Mnohočetné metastázy karcinomu plic, A i B: MR, T1 po KL, str. 28
- Obr. č. 23:** Výstup Prewittova a Robertsova operátoru, str. 30
- Obr. č. 24:** Výstup LoG a Cannyho operátoru, str. 30
- Obr. č. 25:** Princip metody Level set, str. 31
- Obr. č. 26:** Příklad aplikace Aktivních kontur na sken MR mozku, str. 31
- Obr. č. 27:** Segmentační metoda Region growing, str. 32
- Obr. č. 28:** Segmentační metoda Split and merge, str. 32
- Obr. č. 29:** Princip shlukové analýzy, str. 33
- Obr. č. 30:** Znázornění aktivních kontur bez gradientu, str. 36
- Obr. č. 31:** Vývojový diagram kroků požitého algoritmu, str. 38

**Obr. č. 32:** Ukázka řezu obrazových dat MR mozku u pacienta č.1 s tumorem vyznačeným červeným rámečkem, str. 39

**Obr. č. 33:** Ukázka řezu obrazových dat MR mozku u pacienta č.2 s tumorem vyznačeným červeným rámečkem, str. 39

**Obr. č. 34:** Ukázka řezu obrazových dat MR mozku u pacienta č.3 s tumorem vyznačeným červeným rámečkem, str. 40

**Obr. č. 35:** Transformace jasové stupnice, str. 41

**Obr. č. 36:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.1, str. 41

**Obr. č. 37:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.2, str. 41

**Obr. č. 38:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.3, str. 42

**Obr. č. 39:** Definice inicializační elipsy pro segmentaci aktivními konturami, str. 42

**Obr. č. 40:** Umístění inicializační kontury pomocí kurzoru, str. 44

**Obr. č. 41:** Inicializační kontura NumIter 1, str. 44

**Obr. č. 42:** Inicializační kontura NumIter 50, str. 45

**Obr. č. 43:** Inicializační kontura NumIter 100, str. 45

**Obr. č. 44:** Inicializační kontura NumIter 150, str. 46

**Obr. č. 45:** Inicializační kontura NumIter 200, str. 46

**Obr. č. 46:** Ukázka segmentačního modelu u pacienta č.1 u dvou různých datasetů z jiných časových období snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200, str. 47

**Obr. č. 47:** Ukázka segmentačního modelu u pacienta č.2 u dvou různých datasetů z jiných časových období snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200, str. 47

**Obr. č. 48:** Ukázka segmentačního modelu u pacienta č.3 u dvou různých datasetů z jiných časových období snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200, str. 48

**Obr. č. 49:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 1, str. 49

**Obr. č. 50:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 2, str. 49

**Obr. č. 51:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 3, str. 49

**Obr. č. 52:** Příklad převedené segmentační křivky na binární obraz u dat pacienta č.1, str. 50

**Obr. č. 53:** Příklad převedené segmentační křivky na binární obraz u dat pacienta č.2, str. 50



- Obr. č. 54:** *Příklad převedené segmentační křivky na binární obraz u dat pacienta č.3, str. 50*
- Obr. č. 55:** *Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 1, str. 52*
- Obr. č. 56:** *Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 2, str. 52*
- Obr. č. 57:** *Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 3, str. 53*
- Obr. č. 58:** *Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 1, str. 53*
- Obr. č. 59:** *Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 2, str. 53*
- Obr. č. 60:** *Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 3, str. 54*
- Obr. č. 61:** *Příklad grafu znázorňující index korelace pro dané obrazy u jednoho vyšetření u pacienta č. 2, str. 56*
- Obr. č. 62:** *Příklad grafu znázorňující SSIM pro dané obrazy u jednoho vyšetření u pacienta č. 2, str. 59*
- Obr. č. 63:** *Graf znázorňující index korelace pro jednotlivé vyšetření, str. 60*
- Obr. č. 64:** *Graf znázorňující index strukturální podobnosti pro jednotlivé vyšetření, str. 60*
- Obr. č. 65:** *Grafické uživatelské rozhraní, str. 61*
- Obr. č. 66:** *Výběr požadované složky v PC, str. 62*
- Obr. č. 67:** *Vložení inicializační kontury, str. 62*
- Obr. č. 68:** *Výsledek segmentace v uživatelském rozhraní, str. 63*

## Seznam tabulek

**Tab. č. 1:** Základní typy T1 sekvencí, str. 16

**Tab. č. 2:** Základní typy T2 sekvencí, str. 17

**Tab. č. 3:** Parametry MR mozku v T1 SE, str.19

**Tab. č. 4:** Parametry MR mozku v T1 IR, str.19

**Tab. č. 5:** Parametry MR mozku v T2 vážený obraz, str. 20

**Tab. č. 6:** Parametry MR mozku v sekvenci FLAIR, str. 20

**Tab. č. 7:** Parametry MR mozku v sekvenci T1 s kontrastní látkou, str. 21

**Tab. č. 8:** Parametry MR mozku v sekvenci T2 TSE 3D, str. 21

**Tab. č. 9:** Rozdělení datasetů u pacienta č. 1 a počty vybraných scanů pro automatickou segmentaci, str. 39

**Tab. č. 10:** Rozdělení datasetů u pacienta č. 2 a počty vybraných scanů pro automatickou segmentaci, str. 39

**Tab. č. 11:** Rozdělení datasetů u pacienta č. 3 a počty vybraných scanů pro automatickou segmentaci, str. 40

**Tab. č. 12:** Nastavení parametrů pro segmentační model, str. 43

**Tab. č. 13:** Volumetrie tumoru pacienta č.1, str. 51

**Tab. č. 14:** Volumetrie tumoru pacienta č.2, str. 51

**Tab. č. 15:** Volumetrie tumoru pacienta č.3, str. 51

**Tab. č. 16:** Hodnoty korelačního koeficientu u pacienta č.1, str. 55

**Tab. č. 17:** Hodnoty korelačního koeficientu u pacienta č.2, str. 55

**Tab. č. 18:** Hodnoty korelačního koeficientu u pacienta č.3, str. 56

**Tab. č. 19:** Hodnoty SSIM u pacienta č.1, str. 57

**Tab. č. 20:** Hodnoty SSIM u pacienta č.2, str. 58

**Tab. č. 21:** Hodnoty SSIM u pacienta č.3, str. 58

## Úvod

Mozkové nádory patří mezi jedno z nejčastějších onkologických onemocnění. V České republice je každý rok toto onemocnění diagnostikováno u více než 700 osob, z nichž nadpoloviční většinu tvoří muži. Tato data jsou přístupné z Národního onkologického registru ČR, a díky tomu lze zjistit, že nádorovým onemocněním trpí rok od roku více lidí. Hlavní zásluhou na tomto faktu má i včasnější a lepší diagnostika, která se stává dostupnější všem.

Terapie u nádorových onemocnění mozku může být různá. Odvíjí se od typu nádoru, jeho progresi a místě kde se nachází. Mezi nejčastější metody léčby patří radikální chirurgický zákrok, radioterapie, chemoterapie, biologická léčba nebo konzervativní přístup, který spočívá ve sledování nádoru. Konzervativní přístup se využívá u benigních nádoru či u nádoru, kde by chirurgický zákrok nebyl možný či by představoval větší zátěž pro pacienta, než jaký by přinesl terapeutický přístup. Proto je při zaměřování a vypočítávání velikosti nádoru důležitá přesnost.

Diplomová práce je v teoretické části rozdělena do oddílů, které řeší problematiku mozkových tumorů, vyšetřovací metodu magnetickou rezonancí a přehled segmentačních metod. Následně je řešen návrh algoritmu pro segmentaci pomocí aktivních kontur. Tento návrh zahrnuje předzpracování, samotnou segmentaci a výpočet objemu. Kvalita segmentace je dále testována pomocí objektivních evaluačních metod. Nakonec je navrženo uživatelsko-grafické rozhraní pro segmentaci a volumetrii MR obrazových dat.

# 1 TEORETICKÝ ROZBOR

## 1.1 Anatomie mozku

Centrální nervový systém (CNS) se dělí na dvě části, mozek a míchu. Dle anatomického hlediska se mozek dělí na čtyři části, mezi které patří mozkový kmen, mezimozek, mozeček, a koncový mozek. [1]

### Mozkový kmen

Navazuje na páteřní míchu. Nachází se zde centra důležitá pro vitální funkce. Kraniálně přechází v mezimozek a z vrchu je kryt mozečkem. Mozkový kmen tvoří prodloužená mícha, Varolův most a střední mozek.

### Prodloužená mícha

Je spojovacím článkem mezi dalšími oddíly mozku a páteřní míchou, má tvar kužele a mezi její činnosti patří řízení vitálních funkcí, regulace trávení či řízení reflexů obranných či reflexů kašle a kýčání.

### Varolův most

Spojuje prodlouženou míchu s koncovým mozkiem. Řídí některé reflexy jako například rohovkový reflex či okulokardiální reflex. Dále se podílí na regulaci dechu.

### Střední mozek

Má důležitou roli ve zprostředkování důležitých reflexů zrakových či sluchových. Prochází jím například sluchové, somatosenzorické a spinothalamické dráhy.

### Mezimozek

Mezimozek navazuje na mozkový kmen. Je uložen mezi dvěma hemisférami koncového mozku. Skládá se z pěti oddílů: thalamu, subthalamu, hypothalamu, metathalamu a epithalamu. Thalamus vychází ve výběžky, které tvoří stěnu III. mozkové komory.

Mezimozek se podílí na řadě důležitých funkcí. Mezi nejzajímavější patří termoregulace, regulace hladu a žízně, sexuální funkce nebo sekrece hormonu, za které zodpovídá oddíl hypothalamus.

Mezimozek obsahuje také podvěsek mozkový tzv. hypofýzu, která zastupuje především hormonální funkci.

### Mozeček

Mozeček má vrstevnatou strukturu, kde na povrchu má šedou hmotu tvořenou těly neuronů (kůra) a uvnitř bílou hmotu tvořenou nervovými vlákny. Mozečková kůra je zvrásněná záhyby.

Mezi funkce mozečku patří udržování rovnováhy a stoje, udržování svalového napětí (tonu) a řízení a koordinace pohybů. [1,2]

### Koncový mozek


Je tvořen dvěma hemisférami a je největší částí mozku. Hemisféry obsahují postranní komory, které jsou propojené s III. mozkovou komorou v mezimozku.

Koncový mozek se rozděluje na dílčí části (laloky) dle místa uložení – lalok čelní, temenní, spánkový a týlní.

Obsahuje také malý lalůček insulu (Insulární kortex), který se podílí na funkci vědomí a regulaci emocí jako je empatie, soucit nebo sebeuvědomění.

### Mozkové obaly

Celý mozek je chráněn mozkovými obaly. Omozečnice neboli pia mater je měkká plena vypadající jako tenká blanka, která přímo naléhá na mozek. Nad omozečnicí je pavučnice, arachnoidea, která je bezcévná a obsahuje síť vláken vytvářející prostor mezi ní a omozečnicí, který je vyplněn mozkomíšním mokem. Mezi pavučnicí a kostí lebky se nachází ještě tvrdá plena, která je vazivovým obalem hustě protkaný cévami. [1, 2]



**Obr. č. 1:** Anatomie mozku [3]

## 1.2 Magnetická rezonance

Magnetická rezonance (MRI – Magnetic Resonance Imaging) je zobrazovací metoda, která je neinvazivní a poskytující informace o anatomické stavbě zobrazovaného objektu a také o fyziologii jednotlivých orgánů. Hlavním rozdílem mezi CT a MR vyšetřením je, že MR nevyužívá ionizující záření.

Základní popisem každé částice je existence vnitřního spinového momentu hybnosti, takzvaný spin neboli míra rotace. Spin si lze představit jako rotaci částice kolem vlastní osy. Jádra atomů jsou složena z protonů a neutronů. Atomová jádra, která mají lichý počet protonů, vykazují magnetický moment. Nejideálnějším prvkem pro zobrazení magnetickou rezonancí je vodík, protože jeho magnetický moment je relativně silný. Má v jádře atomu pouze jeden proton a taky je hojně zastoupen v lidském těle, zhruba ze 60%. Osy protonů vodíku v lidském těle jsou orientovány náhodně, jejich magnetický moment se ruší, a proto je navenek nulový. Pokud jsou protony postaveny do statického magnetického pole, protony se uspořádají rovnoběžně se siločarami magnetického pole. V paralelním postavení se nachází podstatná část protonů, menší zbytek je otočen o 180° do takzvaného antiparalelního postavení. [4]


Intenzita statického magnetického pole je interpretována v jednotkách Tesla (T). V současné době nejvyužívanější přístroje v diagnostice mají intenzitu 1,5 T. Trendem poslední doby v diagnostice i výzkumu je využití magnetického pole o velikosti 3 T. Statické magnetické pole způsobuje precesi. Precese znamená rotační pohyb v transverzální rovině. Protony nerotují synchronně, nýbrž rozfázovaně, což znamená, že každý proton se otáčí po stejné kruhové dráze stejnou rychlostí, ale nachází se aktuálně na jiném místě kruhu. Frekvence precesního pohybu je závislá na velikosti statického magnetického pole a gyromagnetické konstantě. [4, 5]

Závislost je vyjádřena pomocí Larmorovy rovnice (1):

$$\omega = B_0 \cdot \gamma \quad (1)$$

Rozdíl mezi postavením spinu v paralelním a antiparalelním postavení ve srovnání se siločarami magnetického pole je velmi malý, téměř se nedá zjistit. Pokud se změní uspořádání protonů tím, že se dodá z venku vysokofrekvenční radiofrekvenční impuls, tak magnetický moment bude jiný ve srovnání se siločarami a lze jej změřit. Po takovém impulsu odpovídající Larmorově frekvenci dochází k excitaci a překlopení spinu protonu o 90° nebo 180°. V závislosti na radiofrekvenčním impulsu budou protony provádět synchronní precesi a mají zvýšenou transverzální magnetizaci. Po ukončení impulsu se proton vrací do svého původního stavu a nastává desynchronizace precesního pohybu. Tento jev je popsán jako relaxace a bývá delší v porovnání s excitací. Energie, kterou proton vydává při návratu do původní polohy, se nachází v podobě elektromagnetického záření a je převedena v cívce na povrchu těla na energii elektrickou, která je měřena. Polohu protonu v trojrozměrném prostoru lze určit pomocí gradientních cívek. Jsou nainstalovány do statického pole ve třech na sebe kolmých rovinách x, y, z a určují rovinu řezu a šířku zobrazené vrstvy. [4, 5]

Při použití  $90^\circ$  a  $180^\circ$  impulsů se využije polovičních časů, který se sečte do jednoho času a ten se pak nazývá echo čas – TE (Time to Echo). Echo je charakterizováno jako příjem signálu po vyslání  $180^\circ$  impulsu. Čas, který uplyne mezi jednotlivým  $90^\circ$  pulsy se pak nazývá repetiční čas – TR (Time to Repeat).



**Obr. č. 2:** Precesní pohyb [6]

### 1.2.1 Základní sekvence

Základní sekvence v MR jsou tzv. spin-echo (SE) sekvence, nověji turbo spin – echo (TSE), mezi které se řadí T1, T2 a PD. Mezi nejčastější vyšetřovací techniky patří měření T1 a T2 relaxačních časů. Excitační impulsy se v čase jednotlivých relaxací opakují v sériích, a to nazýváme sekvence.

#### T1

U T1 sekvencí dochází k postupnému zvětšování podélného vektoru magnetizace a čas, za jaký dojde k obnově tohoto vektoru na 63 %, podélná relaxace neboli spin-mřížka relaxace. Zároveň však dochází ke ztrátě vektoru příčné magnetizace vymizením synchronního pohybu protonů, což je důsledek vzájemného působení magnetických polí jednotlivých částic.

Tyto obrazy mají krátké TR i TE. Čas TR může být například 500ms a TE 20ms.

Čas T1 slouží k přesnému zobrazení anatomických struktur. T1 signál bývá silnější, když se zkrátí relaxační doba. [8]

|                              |        |                     |
|------------------------------|--------|---------------------|
| Tuk                          | bílý   | hypersignální       |
| Solidní tkáň (mozek)         | světlý | lehce hypersignální |
| Tekutina (likvor, moč, žluč) | tmavý  | hyposignální        |
| Kalcifikace, proudící krev   | černý  | asignální           |

**Tab. č. 1:** Základní typy T1 sekvencí [8]

## T2

Čas, za který klesne vektor příčné magnetizace na 37 % své hodnoty se označuje T2 příčná relaxace, pojmenovaná jako spin-spin relaxace.

T2 vážené obrazy mají naopak dlouhé TR i TE. TR může být v tomto případě například 2000ms a TE může trvat 90ms.

Patologické léze obecně obsahují větší množství vody, a proto jsou výrazněji zachyceny v čase T2. Doba relaxace je zde delší a zobrazení těchto struktur se oproti T1 signálu liší.


|                              |        |               |
|------------------------------|--------|---------------|
| Tuk                          | šedý   | izosignální   |
| Solidní tkáň (mozek)         | tmavý  | hyposignální  |
| Tekutina (likvor, moč, žluč) | světlá | hypersignální |
| Kalcifikace, proudící krev   | černý  | asignální     |

**Tab. č. 2:** Základní typy T2 sekvencí [8]

## PD

Proton denzitní obrazy jsou modifikací T2 obrazu. Tato sekvence závisí na hustotě protonů vodíku. PD obrazy vznikají pomocí 90° RF pulzu který vychyluje protony o 90°. Využívá se méně často než obrazy T1 a T2.

Mezi speciální sekvence řadíme Inversion recovery (IR), což znamená obrácená sekvence obnovy podélné magnetizace. Probíhá přidáním 180° RF pulzu před základní spin – echo 90° a 180°. Doba, která uběhne mezi 180° a 90° pulzem se nazývá Inversion Time. Tyto sekvence se používají v případech, kdy chceme potlačit některé struktury jako je tekutina či tuk. Pak se zájmové struktury lepe zobrazí a rozliší.



**Obr. č. 3:** Porovnání PD, T1 a T2 váženého obrazu u MRI mozku [9]



Pomocí **STIR** sekvence lze potlačit tkáně s krátkým relaxačním časem. Sekvence je založena na  $180^\circ$  preparačním impulzu a poté v době, kdy je signál rychle relaxujících tkání nulový, se vyšle  $90^\circ$  excitační pulz. Tato kombinace zajistí tkáním, které v době vyslání excitačního pulzu měli nulovou podélnou magnetizaci, že se nezobrazí ve výsledném obraze. Tuto sekvenci lze využít k potlačení tuku a má využití u vyšetření páteře nebo velkých kloubů.

Další metoda nazvaná **FLAIR** je podobná principu STIR sekvence. Rozdíl je v prodloužení časů mezi  $180^\circ$  a  $90^\circ$  pulzem, aby  $90^\circ$  excitační pulz byl vyslán v čase, kdy budou mít dlouho relaxující tkáně nulovou hodnotu podélné magnetizace. Výsledkem je nezobrazení tkání s dlouhým relaxačním časem, mezi které patří například tekutina. FLAIR sekvence má velký význam v diagnostice mozkomíšní sklerózy. [5,7]

### 1.2.2 MRI mozku

Při vyšetření mozku magnetickou resonancí se rozlišují v obraze místa s nižší intenzitou signálu, které se nazývají hyposignální nebo hypointenzní. Místa, které se jeví světlejší, jsou hypersignální nebo hyperintenzní. A tkáně, které nevykazují signál jako například krev nebo kalcifikace, se nazývají asignální.

Sekvence používané pro vyšetření dané patologie a její parametry u MR mozku jsou specifické pro dané pracoviště a můžou se v různých nemocnicích lišit. Tyto parametry jsou dané v místních standardech, které si nemocnice určuje sama.

Sekvence uvedené v následující kapitole patří mezi základní protokoly pro vyšetření mozku a nastavení parametru platí pro nemocnici v Hradci Králové, pro přístroj Siemens Avanto 1,5 T. [24]




**Obr. č. 4:** Magnetická resonance Siemens Avanto 1,5T [11]

### 1.2.3 Sekvence

#### T1 SE

| Sekvence | Rovina    | Vrstva mm | TR ms | TE ms | Čas  |
|----------|-----------|-----------|-------|-------|------|
| SE       | Sagitální | 5         | 550   | 8,9   | 3:07 |

Tab. č. 3: Parametry MR mozku v T1 SE [8]



Obr. č. 5: Sekvence T1 SE [24]

#### T1 IR

| Sekvence | Rovina    | Vrstva mm | TR ms | TE ms | Čas  |
|----------|-----------|-----------|-------|-------|------|
| IR       | Sagitální | 4         | 2000  | 7,4   | 3:18 |

Tab. č. 4: Parametry MR mozku v T1 IR [8]




Obr. č. 6: Sekvence T1 IR [24]

## T2 TSE

| Sekvence | Rovina        | Vrstva mm | TR ms     | TE ms | Čas  |
|----------|---------------|-----------|-----------|-------|------|
| TSE      | Transverzální | 4         | 3000-4000 | 80    | 1:42 |

**Tab. č. 5:** Parametry MR mozku v T2 vážený obraz [8]




**Obr. č. 7:** Sekvence T2 TSE [24]

## FLAIR

| Sekvence | Rovina        | Vrstva mm | TR ms | TE ms | Čas  |
|----------|---------------|-----------|-------|-------|------|
| TSE      | Transverzální | 4         | 11000 | 125   | 3:18 |

**Tab. č. 6:** Parametry MR mozku v sekvenci FLAIR [8]




**Obr. č. 8:** Sekvence FLAIR [24]

### T1 + KL

| Sekvence | Rovina        | Vrstva mm | TR ms | TE ms | Čas  |
|----------|---------------|-----------|-------|-------|------|
| SE       | Transverzální | 5         | 470   | 8,1   | 2:24 |

**Tab. č. 7:** Parametry MR mozku v sekvenci T1 s kontrastní látkou [8]




**Obr. č. 9:** Sekvence T1 + KL [24]

### T2 TSE 3D

| Sekvence | Rovina        | Vrstva mm | TR ms | TE ms | Čas  |
|----------|---------------|-----------|-------|-------|------|
| TSE 3D   | Transverzální | 0,6       | 1200  | 85    | 5:09 |

**Tab. č. 8:** Parametry MR mozku v sekvenci T2 TSE 3D [8]



**Obr. č. 10:** Sekvence T2 TSE 3D [24]

### 1.2.4 Průběh vyšetření

Pacient bývá uložen v poloze na zádech, hlavou do gantry MRI. Aby se mohlo vyšetření provést, musí se nad hlavu pacienta umístit povrchová hlavová cívka. Vyrábí se různými výrobci, mají stejný účel, ale mohou se lišit v drobných technických parametrech či designu.

Základními hlavovými cívkami jsou cívky kvadraturní (CP - Circular Polarized), které tvoří jeden celek a obklopuje pacientovu hlavu. V dnešní době se však pracuje na nahrazení modernějšími a technologicky vyspělejšími tzv. "Phased-array" cívkami, které obsahují na sobě nezávislé segmenty v integrovaném obvodu a jsou opět uloženy kolem hlavy pacienta, existují např. 8 kanálové cívky a 16 kanálové cívky. Jedna z výhod více segmentových cívek je, že vyhlazují magnetické pole ve vyšetřované oblasti, což se využívá kvůli velkým rozdílům signálu na periferních a centrálních částech mozku a získá se tak lepší obraz.

Pacient v poloze na zádech musí mít dostatečné pohodlí, jelikož vyšetření trvá řádově desítky minut a pacient musí tuto dobu setrvat v dané pozici. Proto se pacientovi například podkládají nohy vhodnými pomůckami pro zajištění dostatečného komfortu.

Vyšetření může být pro pacienty psychicky náročné z důvodu hluku při vyšetření nebo stísněného prostoru gantry, do kterého je pacient zavážen. U citlivějších pacientů je možné podat medikaci, která ho zklidní, dále mohou pomoci nasazená sluchátka proti hluku a vhodné umístění tlačítka, které může pacient během vyšetření použít, když se nebude cítit dobře nebo se z jeho strany vyskytne závažný problém. Malým dětem je po domluvě s lékařem anesteziologem a pod jeho dohledem podána sedace neboli farmakologicky navozená snížená úroveň vědomí, aby pro ně nebylo vyšetření stresující a vydrželi nehybně ležet. [8,10]



**Obr. č. 11:** Uložení pacienta s CP hlavovou cívkou značky Siemens [11]

## 1.3 Nádory mozku

Nádory mozku se dělí do několika tříd.

Primární jsou nádory, které vyrůstají přímo z mozkových tkání nebo jeho obalů. Sekundární nádory jsou druhotná ložiska neboli metastázy, které mají původní nádor jinde v těle. Nejčastěji metastazuje do mozku nádor plic, který tvoří až 40 % mozkový metastáz, dále karcinom prsu, ledvin, gastrointestinálního traktu nebo melanom.

Nádory se rozdělují také dle místa, kde se nacházejí. Intraaxiální tumor se nachází a vyrůstá z tkání CNS v jakékoli části mozku. Extraaxiální tumor se nachází až za omozečnicí a vyrůstá z tkáně obalů mozku, pavučnice nebo tvrdé pleny, anebo může postihnout kost.

Světová zdravotnická organizace (WHO) rozděluje nádory dle malignity do čtyř stupňů, kdy první stupeň znamená nádor benigní a čtvrtý maligní. Dále WHO má klasifikaci nádorů CNS nádory podle jejich druhu a povahy na nádory neuroepiteliální tkáně, kraniálních a spinálních nervů, nádory mening, nádory ze zárodečných buněk, selární oblasti a metastatické nádory.

Charakteristika nádorů se rozlišuje na základě typing, staging a grading.

**Typing** stanovuje základní histologii, její typ léze a rozlišení tumoru od podobných lézí

**Staging** stanovuje stupeň, ve kterém se nádor nachází ve smyslu růstu, zjišťují se pomocí radiologických vyšetření

**Grading** stanovuje mikroskopický stupeň nádoru, zjišťují se cytologické znaky a lze dle ní stanovit prognózu, stanovuje se dle čtyř základních znaků, které se buď u pacienta nacházejí nebo ne. Jsou to jaderná atypie, mitóza, patologická cévní proliferace a nekróza tkáně.

- Grade I – jedná se o nádor, který neobsahuje ani jeden ze čtyř znaků, jedná se tudíž o tumor benigní.

- Grade II – nádory s jadernou atypii, tyto nádory jsou semibenigní a pacient se po chirurgickém odstranění dožívá průměrně 3-5 let

- Grade III – nádory, u kterých se objevují dva znaky, jaderná atypie a mitózy. Dá se hovořit o potencionálně maligním tumoru. Po chirurgickém odstranění je přežití pacienta 2-3 roky


- Grade VI – u nádorů toho typu se objevují všechny čtyři znaky Grading. Tumory jsou vysoce maligní a přežití po chirurgickém odstranění bývá 6-15 měsíců. [12]

### 1.3.1 Astrocytomy

Jedná se o gliální tumor vycházející z buněk astrocytů, které patří mezi neuroglie neboli podpůrné buňky neuronů. Existují čtyři skupiny rozdělené dle malignity.

**Astrocytom grade I** se vyskytuje nejčastěji v dětském věku a v pubertě. Nádory se vyznačují pomalým růstem, nízkou možností malignizace a jsou ve většině případů dobře ohraničené, tudíž zde může být indikováno chirurgické odstranění. Místa výskytu jsou mozeček, hypotalamus, mozkový kmen nebo mícha.


**Diagnostika:** **CT** vyšetření ukazuje hypodenzní nebo izodenzní ložiska, u kterých se vyskytuje často cista. V případě tumoru nacházejícího se v hemisférách může být patrná kalcifikace v ložisku. **MR** T1 izo– nebo hypointenzní, T2 hyperintenzní ložisko. Po podání kontrastu u CT i u MR se ložisko zvýrazňuje. Někdy může být přítomný edém blízko lokalizace ložiska. [12]



**Obr. č. 12:** Astrocytom grade I v zadní jámě lební, A: CT po KL, B: MR obraz T1 po KL [12]

**Astrocytom grade II** se vyskytuje často v pubertě a středním věku. Sem patří převážná většina všech astrocytomů. Tumor se vyznačuje pomalým růstem, který je difúzní, což znamená opak ohraničeného tumoru, dochází tak k prorůstání tkáně rozptýleně a až u jedné třetiny nádorů se nachází blízko ložiska cista.

**Diagnostika:** **CT** zobrazuje hypodenzní ložisko, které má nepravidelný tvar a v blízkosti se může vyskytovat edém. **MR** v T1 nízký signál a v T2 jsou patrné hyperintenzní ložiska. [12]




**Obr. č. 13:** Astrocytom grade II v temporálním laloku vlevo, A: CT po KL, B: MR obraz T2 po KL [12]

**Astrocytom grade III** je maligní tumor, u kterého je doba přežití po chirurgickém řešení okolo 16 měsíců. Nejčastěji se nachází ve středním věku a tvoří tak u dospělých většinu maligních gliomů. Tumor se vyznačuje velkou expanzí a edémem.

**Diagnostika:** **CT** hypodenzní, izodenzní nebo i smíšené ložisko. **MR** T1 nízký signál, T2 naopak vysoký signál. [12]






**Obr. č. 14:** Astrocytom grade III, A: CT obraz po KL, B: MR obraz T1 po KL [12]

**Glioblastom grade IV** je vysoce maligní astrocytom, který se projevuje rychlým růstem, expanzí s krvácením a rozpadem léze. Často prorůstá do jiných částí mozku a jeho formace připomíná tvar motýlka.

**Diagnostika:** **CT** se jeví jako hypo, izo i hyperdenzní ložisko nepravidelného tvaru s častou přítomností edému v okolí léze. **MR T1** izo i hypointenzní, v T2 vysoký signál. Na CT i MR patrný po podání KL kolem léze prstenec, který značí nekrotickou tkáň. [12]




**Obr. č. 15:** Glioblastom grade IV parietálního laloku, A: CT obraz po KL, B: MR obraz T1 po KL [12]

### 1.3.2 Oligodendrogliom

Nádory vycházející z buněk obklopující axony neuronů jsou takzvané oligodendrocyty. Řadí se mezi nádory, které se vyskytují ve středním věku. V diagnostice jsou vcelku dobře identifikovatelné pro svůj charakteristický vzhled, který způsobuje kalcifikace v lézi. Ve formě grade I a II jsou tumory ohraničené, pomalu rostoucí, kdežto grade III a IV vytvářejí cysty, často krvácejí, nekrotizují a metastazují likvorem do přidružených oblastí.



Diagnostika: **CT** hypo, izo i hyperdenzní nebo smíšené ložisko. Patrné jsou kalcifikace. **MR** T1 izointenzní, T2 hyperintenzní ložisko. U stadií grade III a IV se zvyšuje denzita i intenzita po podání kontrastní látky. [12]




**Obr. č. 16:** Oligodendrogliom bazálních ganglií, A: nativní CT, B: MR obraz T2 [12]

### 1.3.3 Ependymomy

Nádory dětského věku, které postihují mozkové komory a tím způsobují ve většině případů hydrocefalus nebo blokády komory. Jedná se o vysoce maligní tumor. Metastazují za pomoci likvoru.

Diagnostika: **CT** kde jsou patrné nižší a vyšší intenzity znázorňující nekrózy a kalcifikace. **MR** T1 nízký signál, T2 hyperintenzní. Po podání KL u CT i MR se vybarví ohraničení nádoru. [12]




**Obr. č. 17:** Ependymom III. Komory, A: MR nativní T1, B: MR obraz T2 po KL [12]

### 1.3.4 Neuronální nádory

Tyto nádory zastupují gangliocytoomy a gangliomy nebo neurocytoomy, které rostou pomalu a ohraničeně. Nejčastěji se nacházejí v thalamu, mozečku nebo temporálním laloku. Mezi maligní zástupce patří neuroblastom, který metastáze šíří likvorovou cestou. [12]


Diagnostika: Na **CT i MR** smíšená denzita a intenzita, můžou se projevit jako cysty či kalcifikace.



**Obr. č. 18:** Gangliom mozečku MR (FLAIR) T2 obraz [12]



**Obr. č. 19:** Neurocytom MR T2 obraz [12]




**Obr. č. 20:** Neuronální tumor projevující se jako koloidní cysta MR T1 obraz [12]

### 1.3.5 Nádory mening

Meningeomy jsou největší zástupci mezi nádory mozkových plen. Nádory jsou benigní a vyznačují se pomalým, asymptomatickým růstem. Největší výskyt je v dospělém věku, a tvoří 15–20 % intraaxiálních tumorů. V maligní formě se toto onemocnění vyskytuje v 1-2 % případů.

Diagnostika: CT izo nebo hyperdenzní často sousedící se skeletem, viditelné jsou kalcifikace či edém kolem ložiska. MR T1 i T2 izodenzní což bývá zrádné, po podání KL s velmi vysokým signálem. [12]




**Obr. č. 21:** Meningeom umístěný vedle hypofýzy, A: CT po KL, B: MR T1 obraz [12]

### 1.3.6 Nádorové metastázy

Nádorové metastázy se mohou nacházet ve všech oblastech, tj. skelet, epidurální prostor, meningy či mozková tkáň. Nejčastěji se nachází metastázy v mozkové tkáni. Metastázy nacházející se v intracelulárním prostoru zastupují asi 4-15 % mozkových lézí.

Primární ložiska bývají nejčastěji tumory plic, tumory prsu, melanomu nebo Grawitzova tumoru, což je maligní forma nádoru ledvin.

Metastázy se dělí na ty, které prorůstají přímo z primárního ložiska do mozkových tkání nebo obalů, ty, které začnou růst z patologických buněk donesených krevním řečištěm z primárního tumoru, tzv. hematogenní diseminace anebo metastázy vzniklé roztroušením cestou mozkomíšního moku. [12]



**Obr. č. 22:** Mnohočetné metastázy karcinomu plic, A i B: MR, T1 po KL [12]

## 1.4 Segmentace obrazu

Segmentace obrazu se řadí mezi jednu z nejdůležitějších oblastí zpracování biomedicínských obrazů. Při segmentaci dochází k identifikaci oblastí v obrazových datech, dle umístění nebo dle důležitosti. V praxi je možné provést segmentaci objektu, který je v oblasti zájmu, od pozadí, které není důležité. Bohužel při špatně zvolené segmentační metodě může dojít k nežádoucímu ztracení dat, či snížení jejich kvality.

Obraz si lze představit jako jednotlivé pixely, kterým náleží index segmentu, kde se nachází. Pomocí segmentace lze identifikovat jednu jedinou oblast zájmu, nebo více objektů, které mají podobné či stejné znaky. Segmentační metody se stále vyvíjejí a mohou být manuální, poloautomatické či automatické.

Manuální je nejstarší a nejpracnější metoda, kterou provádí sám lékař či specialista. Lékař v obraze provádí manuální anotaci objektu zájmu, pracně kreslí linku kolem objektu v rámci jednotlivých řezů a následně tento objekt, například tumor, změří a vypočítává jeho objem. U této metody odpadá možnost chybného označení segmentu algoritmem, ale zvyšuje se možnost lidské chyby, z důvodu časové náročnosti a zkušenosti jednotlivých lékařů. Další problém může nastat, když by měla být obrazová data, na kterých byla provedena segmentace, porovnána s novými daty, aby se zjistila případná progresse nádorů či účinnost léčby. V tomto případě je určený na klinice jediný lékař, který provádí manuální segmentaci, protože každý lékař má jiné zvyklosti a data by byla neprůkazná. Dále například kontroly v rámci různých nemocnic u stejného pacienta jsou v tomto případě komplikované, protože se zde odrážejí standardy segmentace typické pro toto pracoviště.

Poloautomatické metody jsou novější. Je nutná nejdříve manuální inicializace, aby se získala potřebná informace, která zaručí vytyčení zkoumané oblasti označením několika pixelů a algoritmus již sám provede segmentaci. Nevýhoda je, že zde musí být přítomný manuální zásah a získaný segment musí být zkontrolován lékařem, zda odpovídá skutečné oblasti zájmu. U této metody je menší časová náročnost díky segmentačnímu algoritmu.

Automatická metoda funguje bez manuální inicializace ve zkoumaném obraze. Bohužel samotný algoritmus je povětšinou třeba naučit pomocí testovacích dat, co má v obraze hledat a jaká je oblast zájmu pro segmentaci. Příkladem mohou být neuronové sítě, kde je vložen například obraz skeletu ruky, ale je potřebné algoritmu říct, co to je, aby příště dokázal přirovnat obraz a správně ho zařadit. Toto učení je často nutné provést až s tisíci obrazy. Metoda je náročná na vytvoření softwaru, ale následné zpracování obrazu je nejrychlejší. Takto provedené segmentace musí být také verifikovány lékařem, jelikož může nastat chyba algoritmu. [13,14,15]



### 1.4.1 Metody založené na principu detekce hran

#### Hranové detektory

Metoda založená na zkoumání rozdílů mezi dvěma různými rysy, jako je rozdíl v jasů nebo kontrast, nebo velikost gradientu. Je to velice přirozené, jelikož jedním z hlavních rozpoznávacích aspektů živočichů je právě jas sledovaného objektu. Algoritmus vyhledává v obraze oblasti, kde se výrazně mění hodnota jasu, která bývá označována jako hodnota obrazové funkce  $f(x, y)$ . Změna funkce popisuje její gradient a matematicky se vypočítává pomocí parciálních derivací o dvou proměnných.

Metod pro detekci hran je několik a každá má trochu odlišný výsledek kvůli přístupu k hraně a obrazu. Nejčastěji se vyskytují metody 1. a 2. derivace. V každém případě výsledek samotného hranového detektoru je hranová mapa zobrazující linii kontrastu mezi světlou a tmavou oblastí v obraze. [14]

Mezi základní detektory patří u 1. derivace Robertsův, Prewittův nebo Sobelův operátor. U 2. derivace máme například LoG (Marr-Hildreth) nebo Cannyho operátor.



**Obr. č. 23:** Výstup Prewittova a Robertsova operátoru[25]



**Obr. č. 24:** Výstup LoG a Cannyho operátoru[25]

## Aktivní kontury


Metoda, při které dochází k postupnému tvarování kontur ze středové části objektu k jeho hraně. Aktivní kontura může být definována jako uzavřená řízená kontura, která se vlivem vnitřních, obrazových a vnějších sil deformuje. Vnitřní síly se značí  $E_N$  a způsobují hladkost průběhu kontury. Obrazové síly značené  $E_I$  pomáhají usměrňovat tvarování kontury k hraně objektu. Vnější síly  $E_T$  značí výsledek počátečního umístění kontury.

## Level set


Obdobná metoda jako aktivní kontury, rozdíl je však v tvarování kontury, kterou netvarujeme přímo nýbrž pomocí funkce level set.

Funkce pracující ve více dimenzích, při kterém je určen příslušný tvar, například jehlan a řez nulovou hladinou (rovině  $x, y$ ) je počátek křivky tzv. zero level set. Každému bodu nacházejícímu se nad nebo pod nulovou hladinou přiřadí výšku roviny  $x, y$ . Povrch funkce postupně přiřazuje hodnoty vzhledem k zadaným obrazovým gradientům, tím se adaptuje na celý objekt.

Metoda se dá využít i na obrazově složitější objekty. [15]



**Obr. č. 25:** Princip metody Level set [15]




**Obr. č. 26:** Příklad aplikace Aktivních kontur na sken MR mozku [26]

## 1.4.2 Metody založené na oblasti v obraze

### Region growing

Metoda narůstání oblastí se řadí mezi segmentační metody založené na iterativním rozdělení obrazu na oblasti. Princip metody spočívá na začátku na rozložení bodů v obraze, ze kterých narůstají jednotlivé oblasti. Důležitým faktorem je správné rozložení bodů v obraze, který zajistí správnou segmentaci dané problematiky. Pokud body umístíme nerovnoměrně vzniknou oblasti s malým výskytem bodů a oblasti s velkou hustotou výskytu. Z těchto bodů iterativně rostou oblasti po pixelech. Segmentace je zakončená, když všechny pixely jsou přijaté do nějaké z oblastí dle nejvyššího stupně příslušnosti. [15]




**Obr. č. 27:** Segmentační metoda *Region growing* [16]

### Split and merge

Segmentační metoda založená na principu rozdělení a sloučení obrazu. Obraz je postupně rozdělován do kvadrantů na základě kritéria homogenity a podobné regiony jsou sloučeny, aby vytvořily segmentovanou oblast. Tato technika zahrnuje strukturu čtyřúhelníků, kde existuje vztah mezi „rodičem“ a „dítětem“, kde celková oblast je rodič a každá ze čtyř částí je dítě.

Na začátku se definuje kritérium pro homogenitu, rozdělí se obrázek do oblastí se stejnou velikostí a vypočítá se homogenita pro každou oblast. Pokud je oblast homogenní, sloučí se se svými sousedy. Takto se to opakuje, dokud se nepřeměří homogenita ve všech oblastech. [13]



**Obr. č. 28:** Segmentační metoda *Split and merge* [17]

### 1.4.3 Metody statické

#### Prahování

V této metodě jsou objekty či oblasti charakterizovány konstantní pohltivostí či odrazivostí svého povrchu oproti pozadí, na kterém je objekt umístěn.

Prahování je bodová transformace jasu vstupního obrazu  $g$  na výstupní binární obraz  $f$  s prahem  $T$  obrazového elementu, který náleží objektu či oblasti má hodnotu 1 pixel a ten který náleží pozadí má hodnotu 0:

$$f(i, j) = \begin{cases} 1, & \text{pro } (i, j) \geq T \\ 0, & \text{pro } (i, j) < T \end{cases}$$

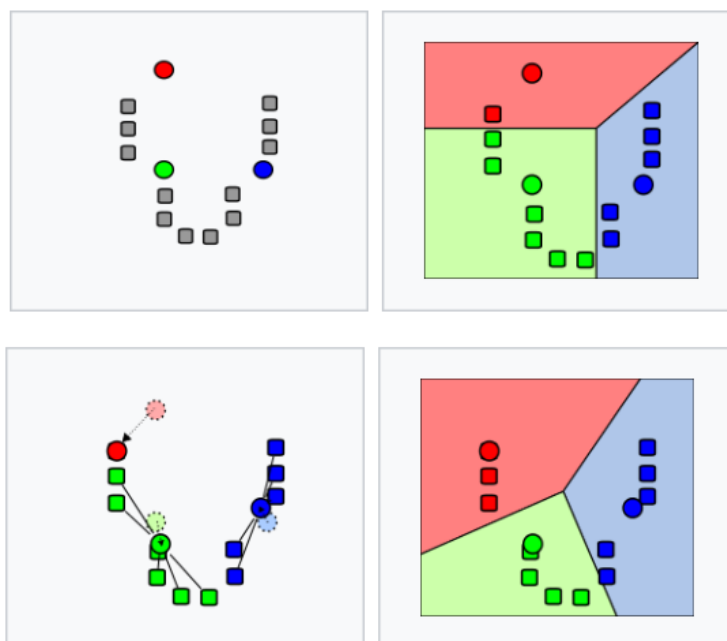
Prahování může mít více podob, prosté nebo s více prahy, dále částečné nebo adaptivní neboli lokální prahování.

Prah lze určit několika způsoby, a to z histogramu, experimentálně, ze statistik, z globální znalosti nebo určení procentní, kde vychází z objemu plochy, kterou objekt na pozadí zaujímá.

#### Shluková analýza

Shluková segmentační metoda využívá metrické prostory, které umožňují přiřazení vzdálenosti pro rozřídění bodů, pixelů do jedné z oblastí. Jde o rozdělení množiny objektu na její podmnožiny, aby ve výsledné oblasti se nacházeli shluky objektů se vzájemnou podobností.

Další hojně používaná metoda se nazývá metoda K-průměru, která patří mezi nehierarchickou shlukovou analýzu.  $K$  značí počet oblastí, který si definujeme a k nim budou přiřazeny jednotlivé body. Definovat tyto oblasti můžeme buď náhodně nebo parametricky. Pro každý bod v obraze se vypočítává vhodná vzdálenost, v tomto případě rozdíl vektorů příznaků umocněný na druhou, od všech oblastí a následně je tento bod přiřazený do nejbližší vzdálené oblasti.



**Obr. č. 29:** Princip shlukové analýzy K-means [18]



## 1.5 Metody aktivních kontur

Metody aktivních kontur jsou hojně využívány k segmentaci obrazu už od svého počátku v osmdesátých letech, kdy o ní jako první začali psát Michael Kass, Andrew Witkin a Demeteri Terzopoulos ve své práci [15]. Tato segmentační metoda je využívána jak v medicíně, k segmentaci obrazových dat CT, MRI, nebo například USG. Také je využívána v různých mobilních aplikacích, detekci pohybu, rozpoznávání osob u kamerového zabezpečení či monitorování dopravní situace. Její využití je široké a je stále kde ji rozvíjet.

### 1.5.1 Aktivní kontury využívající gradient

Metody aktivních kontur, které využívají gradient jako parametr pro výpočet externí energie jsou jednoduché a používáme je v případě obrazu bez šumu

#### Metoda typu snake

Metoda hada patří mezi nejjednodušší a nejstarší metody aktivních kontur. Z definice „had“ vyplývá, že tato metoda se snaží o minimalizaci energie. Energie je dána externí silou, posouvající hada ve směru gradientu. Interní složka energie se snaží zachovat hladkost křivky. Celá energie křivka je zadána pomocí rovnice, kde  $s \in [0, 1]$ :

$$E_{snake} = \int_0^1 E_{int}(v(s)) + E_{ext}(v(s)) ds, \quad (2)$$

kde  $v(s)$  je parametricky zadaná křivka s normalizovaným parametrem  $s$ .  $v(s)$  je možné napsat i,  $v(s) = \{x(s), y(s)\}$ , které odpovídají kartézskými souřadnicím obrazu.  $E_{ext}$  vyjadřuje externí energii a  $E_{int}$  interní energii. Tuto energii dále můžeme přepsat do podoby:

$$E_{snake} = \int_0^1 E_{int}(v(s)) + E_{image}(v(s)) + E_{con}(v(s)) ds \quad (3)$$

kde externí energie je v nezměněné podobě a označuje se  $E_{image}$  a interní energii je rozložena do  $E_{int}$  reprezentující sílu pro zachování tvaru křivky a  $E_{con}$  vyjadřující pružné síly křivky. Poté je potřebné rozepsat jednotlivé energie, aby byl možný jejich explicitní výpočet. První část interní energie rozepíšeme pomocí formule:

$$E_{int} = \frac{1}{2} (\alpha(s)|v_s(s)|^2 + \beta(s)|v_{ss}(s)|^2) \quad (4)$$

kde  $\alpha$  a  $\beta$  jsou empiricky zadané váhy a  $v_s$  s  $v_{ss}$  jsou první, respektive druhá derivace křivky podle parametru  $s$ . Energie obrazu je daná součtem energií využívajících informace z obrazu. Tato energie může být napsaná jako rovnice:

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term} \quad (5)$$

Jednotlivé  $w$  odpovídají váhám, empiricky zadanými, které jsou specifické pro daný typ problému. A jednotlivé energie mohou být vypočítané následujícím způsobem.  $E_{line}$  jako funkce obrazu může být nahrazena ve své nejjednodušší formě intenzitou obrazu,  $E_{edge}$  se počítá pomocí první derivace v obraze a  $E_{term}$  je možné vypočítat pomocí směru gradientu rozmazaného objektu a tato energie se snaží dosáhnout koncové body hran a čar.

Finálně je potřebné vypočítat energii  $E_{con}$  (z rovnice 3). Tu je možné vypočítat na základě její analogie s pružinou, kterou síla teoreticky představuje. Energie pružiny je dána rovnicí:

$$E_{con} = -k(s_1 - s_2)^2 \quad (6)$$

$s_1$  a  $s_2$  jako dva body křivky.

Když se spojí všechny zmíněné energie a iterativní řešení po jednotlivých bodech křivky, může se dosáhnout posunutí křivky k hranám které reprezentují hranice objektu. [19]

### **Tok gradientu vektoru**

Mezi další modifikace základní metody aktivních kontur patří metoda využívající tok gradientu vektoru pro výpočet externí síly obrazu. Výhodou tohoto postupu je možnost detekovat i konkávní hranice objektů. Podstatou metody je vytvoření gradientního vektorového pole. V každém bodě je sestrojený vektor a toto vektorové pole směřuje na nejbližší hrany, ale v homogenních oblastech jsou částečně rozfázované. Je definované jako  $v(x, y) = (u(x, y), v(x, y))$

$$\epsilon = \iint \mu(u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |v - \nabla f|^2 dx dy \quad (7)$$

V rovnici je  $\mu$  kontrolní parametr, který rozhoduje o poměru vlivu jednotlivých částí rovnice na výsledný funkcionál a zároveň i na výsledné pole.

$$\mu \nabla^2 u - (u - f_x)(f_x^2 + f_y^2) = 0 \quad (8)$$

$$\mu \nabla^2 v - (v - f_y)(f_x^2 + f_y^2) = 0$$


$u_x, u_y, v_x, v_y$  jsou derivace jednotlivých složek vektorového pole. Výpočet jednotlivých složek vektorového pole může být realizovaný pomocí výše uvedených rovnic (8). Metoda výpočtu takto definovaných diferenciálních rovnic bude numerická metoda, jakou je metoda Runge-Kutta nebo při zjednodušení Eulerova metoda. Externí energie je ve finále nahrazená hodnotou tohoto vektorového pole. [20]

### 1.5.2 Aktivní kontury bez využití gradientu

Další skupinou metod, které využívají princip aktivních kontur jsou metody, kde parametr pro výpočet externí energie není spojený s gradientem. Tyto křivky bývají často zobrazené jako křivky definované nulovou vrstevnicí. Základní metodou je metoda využívající matematickou formulaci problému s rozdělením množiny hodnot do  $N$  podmnožiny. V případě aktivních kontur  $N$  nabývá hodnoty 2. Základní metoda využívá jako informaci pro výpočet externí energie původní obraz a jeho hodnoty intenzity.

#### Aktivní kontury bez využití hran

Téměř všechny metody, které jsou založené na externí energii nevyužívajícího gradientu se odklánějí od této původní metody. Princip metody spočívá v minimalizaci energie, která je závislá na vlastnostech křivky a intenzitě obrazu. Nejjednodušší vysvětlení by bylo pomocí obrázku se dvěma různými homogenními poli s rozdílnými hodnotami intenzit.



**Obr. č. 30:** Znáznornění aktivních kontur bez gradientu [21]

Definovaná parametrická funkce podle obrázku 30 nabývá kladné hodnoty vně ohraničené oblasti, nulové hodnoty na hranici mezi obrázkem a záporné hodnoty uvnitř ohraničeného objektu.

Křivka  $C = 0$  potom reprezentuje hledanou hranici, která ohraničuje daný objekt. Energie vyjádřená rovnicí může být napsaná jako:

$$\begin{aligned}
 E(c_1, c_2, C) = & \mu l(C) + \vartheta A(C) \\
 & + \lambda_1 \int_{in(C)} |u_0(x, y) - c_2|^2 dx dy \\
 & + \lambda_2 \int_{out(C)} |u_0(x, y) - c_2|^2 dx dy
 \end{aligned} \tag{9}$$


Tato uvedená rovnice vyjadřuje základní vztah využívaný k definice energie, kterou je třeba minimalizovat k dosažení nejlepšího řešení. Konstanty splňují následující podmínky  $\mu, \vartheta \geq 0$  a  $\lambda_1, \lambda_2 > 0$ ,  $u(x, y)$  vyjadřuje původní obraz,  $l(C)$  délku křivky a  $A(C)$  obsah ohraničené plochy křivkou  $C$ ,  $c_1$  a  $c_2$  patří mezi další konstanty závislé na  $C$  a integrály jsou v definovaném v mezích mimo a uvnitř objektu. Pro matematický popis a možnost číselného či analytického řešení je vhodné definovat Heavisideovu funkci.

$$H(z) = \begin{cases} 1, & \text{pre } z \geq 0 \\ 0, & \text{pre } z < 0 \end{cases} \quad (10)$$

Definicí Heavisideové funkce je možné upravit na formální rovnici (10) na vztah, který představuje, částečně zjednodušení a umožňuje použít Euler-Lagrangeovu rovnici pro výpočet změny parametrické funkce  $\varphi(x, y)$ . Křivka  $C$  je definovaná jak nulová vrstevnice parametrické funkce, která v každém bodě nabývá určité hodnoty, jak jsme mohli vidět na obrázku 30.

## 2 PRAKTICKÁ ČÁST

### 2.1 Automatický model pro detekci a extrakci mozkových metastáz



**Obr. č. 31:** Vývojový diagram kroků použitého algoritmu [zdroj vlastní]

Praktická část se zabývá vývojem automatického modelu pro segmentaci mozkových metastáz a následnou volumetrií. Model spočívá v jednotlivých krocích, jak naznačuje diagram u obrázku č. 31.

Obrazová data nejdříve budou načtena do programu MATLAB, poté je předzpracován obraz pomocí jasové transformace, aby bylo docíleno lepšího kontrastu a tím se zvýšila možnost přesnější segmentace. Do takto předzpracovaného obrazu se zanesou kurzorem inicializační kontura (seed point), která se následně začne rozpínat až na okraj tumoru, který se vyznačuje výraznou změnou kontrastu. Po skončení rozpínání na okraj tumoru se křivka zastaví a proběhne extrakce tumoru. U extrahovaného tumoru je nakonec vypočítán objem. Po evaluaci segmentačního modelu bude vytvořeno graficko-uživatelské rozhraní, které bude obsahovat všechny výše zmíněné kroky od načtení dat po výpočet objemu. Bude zhotovena jednoduchá aplikace, která by byla intuitivní pro uživatele, v našem případě lékaře, a aby jim usnadnila práci.

#### 2.1.1 Analýza dat

Data byla získána ve spolupráci s Onkologickou klinikou Fakultní nemocnice Ostrava, která na segmentačním modelu měla zájem.

Datové sady byly poskytnuty od tří pacientů. Jedná se o data magnetické rezonance, která byla pořízena v T1 váženém obraze. Tumor se na daných obrazech jeví jako světlý (hypersignální) oproti okolní mozkové tkáni, která je tmavá (hyposignální). Pacienti měli datové sady z různých časových období, dělící několik týdnů až několik měsíců, kdy byl zkoumán stav (velikost) tumoru. U dvou pacientů byly čtyři datové sady a jeden pacient měl datové sady tři. Jeden dataset obsahuje přibližně 300 až 350 scanů (řezů) mozku, ze kterých byly vybrány a extrahovány do složky pouze řezy, na kterých se tumor nachází. Toto bylo učiněno pro zjednodušení segmentace a snížení výpočetní náročnosti. Tím bylo dosaženo u těchto pacientů, že datasety obsahují pouze 10 až 22 řezů. Z důvodu zachování ochrany osobních údajů jsou tyto vyšetření anonymizována, proto jsou jednotliví pacienti očíslováni.

Všechna obrazová data mají rozměr 512x512 pixelů, s rozlišením 96x96 DPI a 24bitovou hloubkou obrazu.

### Pacient č. 1

Pacient číslo jedna, má čtyři datové sady z období 29.11.2017 až 16.11.2018.

| Datum pořízení MR dat               | 29/11/2017 | 26/1/2018 | 11/9/2018 | 16/11/2018 |
|-------------------------------------|------------|-----------|-----------|------------|
| Počet řezů vybraných pro segmentaci | 19         | 19        | 19        | 22         |

**Tab. č. 9:** Rozdělení datasetů u pacienta č. 1 a počty vybraných scanů pro automatickou segmentaci




**Obr. č. 32:** Ukázka řezu obrazových dat MR mozku u pacienta č.1 s tumorem vyznačeným červeným rámečkem [zdroj vlastní]

### Pacient č. 2

Pacient číslo dva, má čtyři datové sady z období 11.4.2017 až 1.3.2019.

| Datum pořízení MR dat               | 11/4/2017 | 19/6/2018 | 18/12/2018 | 1/3/2019 |
|-------------------------------------|-----------|-----------|------------|----------|
| Počet řezů vybraných pro segmentaci | 12        | 11        | 10         | 13       |

**Tab. č. 10:** Rozdělení datasetů u pacienta č. 2 a počty vybraných scanů pro automatickou segmentaci



**Obr. č. 33:** Ukázka řezu obrazových dat MR mozku u pacienta č.2 s tumorem vyznačeným červeným rámečkem [zdroj vlastní]

### Pacient č.3

Pacient číslo tři, má tři datové sady z období 16.2.2017 až 24.4.2018.

| Datum pořízení MR dat               | 16/2/2017 | 30/6/2017 | 24/4/2018 |
|-------------------------------------|-----------|-----------|-----------|
| Počet řezů vybraných pro segmentaci | 14        | 15        | 14        |

**Tab. č. 11:** Rozdělení datasetů u pacienta č. 3 a počty vybraných scanů pro automatickou segmentaci



**Obr. č. 34:** Ukázka řezu obrazových dat MR mozku u pacienta č.3 s tumorem vyznačeným červeným rámečkem [zdroj vlastní]

### **2.1.2 Předzpracování obrazu**


Dříve než se začne samotnou segmentací na datech je nutné předzpracovat obraz, kvůli zkvalitnění vstupních obrazů a tím i lepším výsledkům segmentace. V diplomové práci byla použita pouze lineární jasová transformace, za účelem lepšího kontrastu mezi tumorem a mozkovou tkání. Již po tomto kroku byly obrazy dobře připravené k segmentaci.

### Jasová transformace


Jasová transformace má za úkol změnu kontrastu obrazu, kde zvýrazní oblasti s vyšší jasovou intenzitou (tumor) a potlačí oblasti s nižší jasovou intenzitou (ostatní mozková tkáň). Po tomto předzpracování obrazových dat, je snazší provádět segmentační metodu, jelikož při změně kontrastu bude na rozpínající se linii působit větší vnější síla a nebude mít tendenci se rozpínat mimo oblast tumoru. Transformace jasové stupnice mění vždy danou vstupní hodnotu jasové funkce na výstupní. Vyjádří se vzorcem:

$$q = T(p) \quad (11)$$


kde  $T$  je transformační funkce,  $p$  je původní stupnice jasu a  $q$  je nová stupnice jasu. [27]



**Obr. č. 35:** Transformace jasové stupnice [28]




**Obr. č. 36:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.1 [zdroj vlastní]



**Obr. č. 37:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.2 [zdroj vlastní]






**Obr. č. 38:** MR řez mozku před (vlevo) a po (vpravo) jasové transformaci u pacienta č.3 [zdroj vlastní]

### 2.1.3 Implementace aktivních kontur v prostředí MATLAB

Implementace automatické segmentační metody v programu MATLAB vychází z článku Li Wanga. [29]

Pro dobrý výsledek segmentace musí být správně zvolen tvar a umístění inicializační kontury. Kontura může mít jakýkoli uzavřený tvar. Nejčastěji bývá kružnice nebo ovál. Umístění je důležité vzhledem k výsledné segmentaci, proto se umístění volí ve středu segmentovaného objektu, aby se zamezilo zachycení okolních struktur, které by mohly být falešně určené jako tumor. V tomto případě byl zvolen tvar elipsy.



**Obr. č. 39:** Definice inicializační elipsy pro segmentaci aktivními konturami [33]

Elipsa je tvořená hlavní poloosou a vedlejší poloosou o definované velikosti. Tyto hodnoty se dají definovat pomocí rovnice:

$$\frac{(x-m)^2}{a^2} + \frac{(y-n)^2}{b^2} = 1 \quad (12)$$

Kde  $x$  a  $y$  jsou obecné souřadnice pixelů,  $a$  a  $b$  značí velikost hlavní a vedlejší poloosy a  $m$  a  $n$  značí souřadnice středu elipsy (tato hodnota se volí při vkládání inicializační kontury, pomocí kurzoru)

Před spuštěním segmentace je důležité správně nastavit také parametry inicializační kontury, které jsou popsány níže, ovlivňující výslednou segmentaci. Musí se nastavit optimálně, vzhledem k zájmovému objektu, tzn. pro různé objekty (např. tumor vs chrupavka) budou jiné hodnoty.

Tato použitá metoda aktivních kontur bez hran, je přizpůsobena snímkům s jasovou nehomogenitou a vysokým obsahem šumu.

Upravená obrazová data byla umístěna do vícerozměrné matice, aby mohla být segmentace spuštěna paralelně. V tomto případě stačí na prvním MR řezu umístit inicializační konturu a ta se přenesne na zbylá obrazová data, přesně do místa, kde byla umístěna na prvním obrazu a kde se nachází tumor. To umožňuje dělat segmentaci bez větších manuálních zásahů.

### Nastavované parametry

- $n$  (NumIter) – počet iteračních kroků
- $\Delta_t$  (timestep) – časový krok posunu křivky (čím je vyšší hodnota daného parametru zvolena, tím rychleji se bude křivka pohybovat, ale o to s větší nepřesností).
- $\mu$  (mu) – konstanta, která zajišťuje, aby se kontura příliš neodchýlila od své určené pozice během své evoluce.
- $\sigma$  (sigma) – parametr Kernelovy funkce, která se snaží řešit nehomogenitu jasové intenzity. Čím je daná hodnota vyšší, tím více se křivka při svém rozpínání vzdaluje od své původní pozice během jednoho iteračního kroku.
- $\varepsilon$  (epsilon) – parametr určuje šířku Diracova impulsu, který zrychluje počáteční pohyb dané inicializované kontury. Čím je nižší hodnota, tím přesnější je finální kontura.
- $c_0$  (c0) – tento parametr násobí hodnoty pixelů uvnitř křivky zápornou hodnotou a vně kontury kladnou hodnotou. Čím vyšší je hodnota, tím rychlejší je počáteční pohyb inicializované kontury.
- $\lambda_1$  (lambda1) – konstanta, která přikládá váhu vnitřní oblasti kontury při evoluci křivky. Je vyjádřena funkcí  $e_1(x)$
- $\lambda_2$  (lambda2) – konstanta, která přikládá váhu vnější oblasti kontury při evoluci křivky. Je vyjádřena funkcí  $e_2(x)$
- $\nu$  (nu) – parametr, ovlivňující délku kontury. Čím je hodnota tohoto parametru vyšší, tím menší délky může kontura při svém rozpínání nabývat, a nepřitahuje příliš nežádoucích artefaktů.
- $\alpha$  (alf) – parametr, díky kterému lze při rozpínání kontury nastavit důraz kladený na energii obrazu, přitahující konturu ke hranám. [30]

Pro účel segmentace mozkových tumorů museli být specificky nastavené parametry vhodné pro tyto struktury. V Matlab byly tedy zvoleny tyto hodnoty:

|                         |                |
|-------------------------|----------------|
| $n$ (NumIter)           | 200            |
| $\Delta_t$ (timestep)   | 0,1            |
| $\mu$ (mu)              | 0,1            |
| $\sigma$ (sigma)        | 7              |
| $\varepsilon$ (epsilon) | 0,5            |
| $c_0$ (c0)              | 10             |
| $\lambda_1$ (lambda1)   | 0,75           |
| $\lambda_2$ (lambda2)   | 0,86           |
| $\nu$ (nu)              | 0,0001*255*255 |
| $\alpha$ (alf)          | 30             |

**Tab. č. 12:** Nastavení parametrů pro segmentační model

### 2.1.4 Průběh segmentačního algoritmu

V této kapitole jsou interpretovány výstupy segmentačního modelu. Po nastavení hodnot je model spuštěn. Načtou se obrazová data do vícerozměrné matice, aby mohla být segmentace spuštěna paralelně pro všechny řezy. Poté dojde k vizualizaci prvního snímku, kde vložíme pomocí kurzoru inicializační konturu.



**Obr. č. 40:** Umístění inicializační kontury pomocí kurzoru [zdroj vlastní]

Následně se umístěná kontura začne rozpínat v jednotlivých přednastavených iteračních krocích.



**Obr. č. 41:** Inicializační kontura NumIter 1 [zdroj vlastní]

50



**Obr. č. 42:** Inicializační kontura Numlter 50 [zdroj vlastní]

100



**Obr. č. 43:** Inicializační kontura Numlter 100 [zdroj vlastní]

150



**Obr. č. 44:** Inicializační kontura Numlter 150 [zdroj vlastní]

200



**Obr. č. 45:** Inicializační kontura Numlter 200 [zdroj vlastní]

Na následujících obrázcích 46 až 48, jsou zobrazeny segmentace na klinických datech u jednotlivých pacientů, vždy u dvou datasetů, které pocházejí z různých časových období. Zobrazen je průběh od vložení inicializační kontury po zobrazení segmentační křivky, která proběhla všemi iteračními kroky.

27/11/2017



11/9/2018



**Obr. č. 46:** Ukázka segmentačního modelu u pacienta č.1 u dvou různých datasetů z jiných časových období, snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200 [zdroj vlastní]

11/4/2017



1/3/2019



**Obr. č. 47:** Ukázka segmentačního modelu u pacienta č.2 u dvou různých datasetů z jiných časových období, snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200 [zdroj vlastní]



16/2/2017



24/4/2018



**Obr. č. 48:** Ukázka segmentačního modelu u pacienta č.3 u dvou různých datasetů z jiných časových období, snímky napravo ukazují vkládání inicializační kontury, uprostřed iterační krok 50 a vlevo iterační krok 200 [zdroj vlastní]

Tato segmentace je prováděna automaticky na zbylých datech ve vícerozměrné matici, do kterých byla při nahrání dat vložena. Takto automatizovaná segmentace probíhající paralelně na všech datech, bez nutnosti vkládat inicializační konturu na každý obraz, je pro uživatele snazší a mnohem rychlejší.


### **Binarizace**

V dalším kroku je segmentovaný obraz převeden na binární obraz. To znamená, že obraz bude nabývat hodnot logické 0, která je zobrazena černě a logické 1, která je zobrazena bíle. Je to krok, který umožní provést volumetrii neboli výpočet obsahu extrahované části obrazu. Binarizace probíhá skrz energetickou mapu, kde všechny hodnoty ( $\varphi < 0$ ) uvnitř segmentační kontury mají hodnotu logické 1 a všechny hodnoty ( $\varphi > 0$ ) vně kontury hodnotu logické 0.


Energetická mapa vyobrazuje rozložení energie při evoluci kontury. Tumorová tkáň je vyobrazená modrou barvou a má zápornou hodnotu. Okolní žlutá oblast, která je bez patologií, má hodnotu kladnou.

Energetické mapy i binární obrazy jsou zobrazeny na stejných ukázkových obrazových datech, na kterých byl ukázán průběh segmentační křivky.

27/11/2017




11/9/2018




**Obr. č. 49:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 1  
[zdroj vlastní]

11/4/2017




1/3/2019




**Obr. č. 50:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 2  
[zdroj vlastní]

16/2/2017



24/4/2018



**Obr. č. 51:** Příklad energetických map zobrazující hodnotu logické 1 modrou barvou u pacienta č. 3  
[zdroj vlastní]



Následující obrazy 52 až 54 zobrazují již převedený obraz na binární. Zájmový objekt je extrahován, kdy záporné oblasti je přiřazena bílá barva s hodnotou logické 1 pro tumor a kladné oblasti černá barva s hodnotou logické 0 pro okolní tkáň.

**27/11/2017**




**11/9/2018**




**Obr. č. 52:** Příklad převedené segmentační křivky na binární obraz u dat pacienta č.1 [zdroj vlastní]

**11/4/2017**




**1/3/2019**




**Obr. č. 53:** Příklad převedené segmentační křivky na binární obraz u dat pacienta č.2 [zdroj vlastní]

**16/2/2017**



**24/4/2018**



**Obr. č. 54:** Příklad převedené segmentační křivky na binární obraz u dat pacienta č.3 [zdroj vlastní]




### 2.1.5 Geneze volumetrického modelu mozkových tumorů

Po získání binárního obrazu se vypočte obsah extrahované části v pixelech a následně se všechny obsahy obrazů (jednotlivých MR řezů) sečtou. Tím je získán jednoduše objem tumoru v pixelech. Nebylo nutné se zabývat výpočtem objemu v jednotkách mm<sup>3</sup>, jelikož je potřeba pouze prokázat růst či úbytek velikosti tumoru.

V následujících tabulkách jsou zpracovány jednotlivé objemy u vyšetření dle data pořízení MR vyšetření. Dále je zde uveden procentuální růst či úbytek tumorové tkáně. Pro počáteční (referenční) hodnotu bylo určeno první provedené vyšetření a je mu přiřazena hodnota 100,00 %. Každý následující procentuální údaj se počítá od prvního prodělaného vyšetření.




Označení  značí růst tumoru a označení  udává úbytek tumoru oproti předešlému vyšetření.

#### Pacient 1

|            | 29/11/2017 | 26/1/2018  | 11/9/2018  | 16/11/ 2018  |
|------------|------------|--|--|--|
| Objem [px] | 4752,4     | 4894,9   | 4761,4   | 6351,8   |
| %          | 100,00 %   |  103,00 % |  100,19 % |  133,69 % |



Tab. č. 13: Volumetrie tumoru pacienta č.1

#### Pacient 2

|            | 11/4/2017 | 19/6/2018  | 18/12/2018   | 1/3/2019   |
|------------|-----------|--|--|--|
| Objem [px] | 1164,3    | 1331,5   | 1521,4   | 1722   |
| %          | 100,00 %  |  114,36 % |  130,67 % |  147,90 % |

Tab. č. 14: Volumetrie tumoru pacienta č.2

#### Pacient 3

|            | 16/2/2017 | 30/6/2017  | 24/4/2018   |
|------------|-----------|--|---|
| Objem [px] | 1394,9    | 1752,3   | 1702,6  |
| %          | 100,00 %  |  125,62 % |  122,06 % |

Tab. č. 15: Volumetrie tumoru pacienta č.3

V tabulkách lze vidět, že se tumor zvětšoval i zmenšoval v čase. Vliv na zmenšení tumoru má probíhající léčba jako ozařování nebo chemoterapie.

Objem je pouze jeden aspekt v hodnocení úspěšnosti léčby. Je také nutné vzít v úvahu celkový stav pacienta a ostatní vyšetřovací metody, avšak MR zůstane důležitá jako vizuální kontrola stavu mozkové tkáně u těchto pacientů po zbytek života.


## 2.2 Evaluace a validace segmentačního modelu

Evaluace je nezbytný krok v práci, aby byla zjištěna účinnost a přesnost segmentačního algoritmu. Evaluace probíhá pomocí korelační analýzy a SSIM, což je index strukturní podobnosti pro měření kvality obrazu. Aby bylo možné provést evaluaci, musí být vytvořena nějaká referenční hodnota, se kterou budeme segmentovaná data porovnávat. V tomto případě je vytvořen námi zlatý standard pomocí metody manuální segmentace.


### Zlatý standard

Aby mohlo být provedeno testování přesnosti modelu, musí být nejdříve určen zlatý standard. V tomto případě ho udává námi vytvořená manuální segmentace, která bude porovnána s automatickým modelem, za účelem získání hodnot určující podobnost mezi těmito segmentacemi.

V programu Matlab byla zvolena metoda pro manuální extrakci v obraze. Kvůli nepravidelnému tvaru tumoru je zvolena funkce 'region', kde je manuálně prováděna anotace mozkových tumorů (Free hand). Po vytvoření linie (uzavřeného kruhového tvaru), se provede vstupem uživatele segmentace a převod obrazu na binární.



**Obr. č. 55:** Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 1 [zdroj vlastní]




**Obr. č. 56:** Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 2 [zdroj vlastní]




**Obr. č. 57:** Manuálně vytvořená segmentační křivka vlevo a vygenerovaný binární obraz vpravo u obrazu pacienta č. 3 [zdroj vlastní]


Na obrázcích 55 až 57 lze vidět, vždy na levé straně, manuálně vytvořená kontura, kterou segmentujeme tumor. Poté je tato segmentační křivka převedena na binární obraz, aby mohlo dojít k evaluaci a porovnání těchto dvou segmentací pomocí metod SSIM a korelačního koeficientu.



**Obr. č. 58:** Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 1 [zdroj vlastní]



**Obr. č. 59:** Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 1 [zdroj vlastní]



**Obr. č. 60:** Porovnání binárních obrazů automatické a manuální segmentace u pacienta č. 1 [zdroj vlastní]

Na obrázcích 58 až 60 je zobrazeno porovnání binárních obrazů automatické a manuální segmentace.

### 2.2.1 Index korelace

Korelace je vztah mezi dvěma veličinami nebo procesy. Korelační analýza se zabývá mírou závislosti náhodných dat a výstupem korelační analýzy pak je korelační koeficient, který určuje míru závislosti. [34].

Nejznámějším měřítkem závislosti mezi dvěma veličinami je Pearsonův korelační koeficient (PPMCC). Korelační koeficient vyjadřuje míru blízkosti lineární vazby, protože korelační analýza popisuje lineární vztahy mezi veličinami.

Párový Pearsonův korelační koeficient  $R$  je vyjádřen:

$$R = \frac{\sum(x_i - \bar{x}) \cdot (y_i - \bar{y})}{(n-1)s_x s_y} \quad (13)$$

$$R = \frac{\sum(x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \cdot \sum(y_i - \bar{y})^2}} \quad (14)$$

Korelační koeficient  $R$  nabývá hodnot od -1 do +1. Druhá mocnina korelačního koeficientu  $R^2$ , zvaného koeficient determinace, nabývá hodnot od 0 do +1. Kde 0 znamená žádnou závislost a 1 znamená plnou závislost. [31]

V následujících třech tabulkách č. 16 až 18 jsou zpracovány hodnoty korelačního koeficientu pro všechny jednotlivé obrazy rozdělené dle data pořízení MR dat. Takto je to rozepsáno pro všechny pacienty. Sloupce určují hodnoty pro jednotlivé obrazy, rozdělené dle data. Řádky jsou očíslovány a značí pořadí obrazů v daném vyšetření.

Čím blíže se výsledná hodnota blíží 1 tím víc shodné segmentace jsou. Nakonec je dole v tabulkách uvedena hodnota průměr, která je vypočítána ze všech obrazů u jednoho vyšetření

**Pacient č.1**

|               | 29/11/2017    | 26/1/2018     | 11/9/ 2018    | 16/11/2018    |
|---------------|---------------|---------------|---------------|---------------|
| 1             | 0,6602        | 0,6480        | 0,7626        | 0,5165        |
| 2             | 0,7806        | 0,7499        | 0,7180        | 0,6894        |
| 3             | 0,8727        | 0,7698        | 0,8596        | 0,9091        |
| 4             | 0,9071        | 0,8317        | 0,8726        | 0,8355        |
| 5             | 0,8654        | 0,8987        | 0,9541        | 0,8267        |
| 6             | 0,9395        | 0,8858        | 0,9168        | 0,9207        |
| 7             | 0,9108        | 0,8687        | 0,9228        | 0,9041        |
| 8             | 0,8775        | 0,8660        | 0,9335        | 0,8594        |
| 9             | 0,8842        | 0,8764        | 0,9159        | 0,8671        |
| 10            | 0,9395        | 0,8821        | 0,9472        | 0,9231        |
| 11            | 0,8642        | 0,8804        | 0,9655        | 0,9248        |
| 12            | 0,9024        | 0,8556        | 0,9222        | 0,8703        |
| 13            | 0,8905        | 0,8252        | 0,9045        | 0,8648        |
| 14            | 0,9380        | 0,8378        | 0,9336        | 0,8737        |
| 15            | 0,9094        | 0,8031        | 0,8816        | 0,8872        |
| 16            | 0,6945        | 0,7773        | 0,8306        | 0,9157        |
| 17            | 0,6427        | 0,6898        | 0,7223        | 0,8720        |
| 18            | 0,5139        | 0,5144        | 0,5098        | 0,8405        |
| 19            | 0,3066        | 0,3488        | 0,3748        | 0,7032        |
| 20            | -             | -             | -             | 0,5489        |
| 21            | -             | -             | -             | 0,3901        |
| 22            | -             | -             | -             | 0,1896        |
| <b>Průměr</b> | <b>0,8052</b> | <b>0,7794</b> | <b>0,8341</b> | <b>0,7787</b> |

**Tab. č. 16:** Hodnoty korelačního koeficientu u pacienta č.1**Pacient č.2**


|               | 11/4/2017     | 19/6/2018     | 18/12/ 2018   | 1/3/2019      |
|---------------|---------------|---------------|---------------|---------------|
| 1             | 0,2326        | 0,6118        | 0,5610        | 0,0935        |
| 2             | 0,7322        | 0,7398        | 0,7376        | 0,6210        |
| 3             | 0,7010        | 0,7866        | 0,8594        | 0,8137        |
| 4             | 0,8466        | 0,8697        | 0,8872        | 0,8684        |
| 5             | 0,8427        | 0,9121        | 0,9157        | 0,9030        |
| 6             | 0,8899        | 0,9498        | 0,9522        | 0,9073        |
| 7             | 0,9147        | 0,9328        | 0,9222        | 0,9262        |
| 8             | 0,9119        | 0,9376        | 0,9004        | 0,9245        |
| 9             | 0,9295        | 0,8884        | 0,8877        | 0,8882        |
| 10            | 0,8877        | 0,8809        | 0,8543        | 0,9384        |
| 11            | 0,9030        | 0,6611        | -             | 0,8956        |
| 12            | 0,4859        | -             | -             | 0,8238        |
| 13            | -             | -             | -             | 0,6237        |
| <b>Průměr</b> | <b>0,7731</b> | <b>0,8337</b> | <b>0,8478</b> | <b>0,7867</b> |

**Tab. č. 17:** Hodnoty korelačního koeficientu u pacienta č.2

### Pacient č.3

|        | 16/2/2017 | 30/6/2017 | 24/4/ 2018 |
|--------|-----------|-----------|------------|
| 1      | 0,5285    | 0,6001    | 0,7145     |
| 2      | 0,8035    | 0,5884    | 0,8310     |
| 3      | 0,9006    | 0,8291    | 0,8763     |
| 4      | 0,9033    | 0,8877    | 0,9090     |
| 5      | 0,8763    | 0,9125    | 0,9412     |
| 6      | 0,9312    | 0,9141    | 0,9301     |
| 7      | 0,9160    | 0,9314    | 0,9078     |
| 8      | 0,9213    | 0,9314    | 0,8938     |
| 9      | 0,9046    | 0,9571    | 0,9194     |
| 10     | 0,9113    | 0,9346    | 0,9438     |
| 11     | 0,8910    | 0,9108    | 0,9086     |
| 12     | 0,9335    | 0,9168    | 0,8815     |
| 13     | 0,9387    | 0,8186    | 0,9013     |
| 14     | 0,0029    | 0,6785    | 0,6588     |
| 15     | -         | 0,6246    | -          |
| Průměr | 0,8116    | 0,8290    | 0,8727     |

Tab. č. 18: Hodnoty korelačního koeficientu u pacienta č.3



Obr. č. 61: Příklad grafu znázorňující index korelace pro dané obrazy u jednoho vyšetření u pacienta č. 2 [zdroj vlastní]

Obrázek 61 ukazuje názorný příklad grafického rozložení hodnot indexu korelace, u pacienta č. 2. Červené křížky znázorňují hodnoty indexu korelace pro každý obraz. Vodorovná osa určuje pořadí srovnávaných obrazů a svislá osa udává hodnotu indexu korelace pro dané vyšetření. Index korelace nabývá hodnot u toho vyšetření od 0,61 až 0,95 a jeho průměrná hodnota je 0,83.

### 2.2.2 SSIM

Měření indexu strukturální podobnosti (Structural similarity) se používá k měření podobnosti mezi dvěma obrazovými daty. Index SSIM je úplná referenční metrika a měření kvality obrazu je založeno na počátečním nezkresleném obrazu jako referenční hodnotě. SSIM je model založený na vnímání, který považuje degradaci obrazu za vnímanou změnu strukturální informace.

Index SSIM se počítá na různých oknech obrázku. Míra mezi dvěma okny  $x$  a  $y$  běžné velikosti  $N \times N$  udává:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (15)$$

Kde  $\mu$  je průměr,  $\sigma$  je rozptyl  $\sigma_{xy}$  je kovariance  $x$  a  $y$ ,  $c_1$  a  $c_2$  jsou dvě proměnné pro stabilizaci rozdělení. [32]

#### Pacient č.1

|               | 29/11/2017    | 26/1/2018     | 11/9/ 2018    | 16/11/2018    |
|---------------|---------------|---------------|---------------|---------------|
| 1             | 0,9974        | 0,9976        | 0,9979        | 0,9975        |
| 2             | 0,9970        | 0,9973        | 0,9966        | 0,9975        |
| 3             | 0,9971        | 0,9967        | 0,9970        | 0,9982        |
| 4             | 0,9971        | 0,9960        | 0,9961        | 0,9958        |
| 5             | 0,9953        | 0,9964        | 0,9977        | 0,9944        |
| 6             | 0,9970        | 0,9948        | 0,9956        | 0,9960        |
| 7             | 0,9954        | 0,9945        | 0,9958        | 0,9947        |
| 8             | 0,9941        | 0,9941        | 0,9964        | 0,9929        |
| 9             | 0,9937        | 0,9943        | 0,9947        | 0,9929        |
| 10            | 0,9932        | 0,9939        | 0,9963        | 0,9940        |
| 11            | 0,9930        | 0,9939        | 0,9973        | 0,9944        |
| 12            | 0,9944        | 0,9927        | 0,9951        | 0,9912        |
| 13            | 0,9929        | 0,9912        | 0,9937        | 0,9908        |
| 14            | 0,9955        | 0,9917        | 0,9948        | 0,9918        |
| 15            | 0,9950        | 0,9920        | 0,9934        | 0,9919        |
| 16            | 0,9913        | 0,9925        | 0,9923        | 0,9928        |
| 17            | 0,9912        | 0,9916        | 0,9919        | 0,9925        |
| 18            | 0,9922        | 0,9914        | 0,9910        | 0,9921        |
| 19            | 0,9914        | 0,9924        | 0,9923        | 0,9905        |
| 20            | -             | -             | -             | 0,9898        |
| 21            | -             | -             | -             | 0,9901        |
| 22            | -             | -             | -             | 0,9939        |
| <b>Průměr</b> | <b>0,9950</b> | <b>0,9940</b> | <b>0,9950</b> | <b>0,9975</b> |

Tab. č. 19: Hodnoty SSIM u pacienta č.1



### Pacient č.2

|               | 11/4/2017     | 19/6/2018     | 18/12/ 2018   | 1/3/2019      |
|---------------|---------------|---------------|---------------|---------------|
| <b>1</b>      | 0,9957        | 0,9965        | 0,9956        | 0,9949        |
| <b>2</b>      | 0,9971        | 0,9964        | 0,9958        | 0,9953        |
| <b>3</b>      | 0,9961        | 0,9962        | 0,9959        | 0,9963        |
| <b>4</b>      | 0,9970        | 0,9967        | 0,9959        | 0,9967        |
| <b>5</b>      | 0,9966        | 0,9969        | 0,9962        | 0,9964        |
| <b>6</b>      | 0,9967        | 0,9980        | 0,9974        | 0,9963        |
| <b>7</b>      | 0,9971        | 0,9970        | 0,9965        | 0,9962        |
| <b>8</b>      | 0,9967        | 0,9976        | 0,9964        | 0,9963        |
| <b>9</b>      | 0,9975        | 0,9966        | 0,9962        | 0,9954        |
| <b>10</b>     | 0,9971        | 0,9970        | 0,9967        | 0,9974        |
| <b>11</b>     | 0,9978        | 0,9956        | -             | 0,9966        |
| <b>12</b>     | 0,9982        | -             | -             | 0,9968        |
| <b>13</b>     | -             | -             | -             | 0,9983        |
| <b>Průměr</b> | <b>0,9970</b> | <b>0,9968</b> | <b>0,9962</b> | <b>0,9964</b> |

**Tab. č. 20:** Hodnoty SSIM u pacienta č.2

### Pacient č.3

|               | 16/2/2017     | 30/6/2017     | 24/4/ 2018    |
|---------------|---------------|---------------|---------------|
| <b>1</b>      | 0,9970        | 0,9974        | 0,9967        |
| <b>2</b>      | 0,9967        | 0,9958        | 0,9968        |
| <b>3</b>      | 0,9976        | 0,9969        | 0,9966        |
| <b>4</b>      | 0,9970        | 0,9967        | 0,9969        |
| <b>5</b>      | 0,9958        | 0,9968        | 0,9976        |
| <b>6</b>      | 0,9975        | 0,9966        | 0,9973        |
| <b>7</b>      | 0,9970        | 0,9971        | 0,9962        |
| <b>8</b>      | 0,9974        | 0,9980        | 0,9961        |
| <b>9</b>      | 0,9970        | 0,9979        | 0,9968        |
| <b>10</b>     | 0,9974        | 0,9974        | 0,9977        |
| <b>11</b>     | 0,9974        | 0,9971        | 0,9971        |
| <b>12</b>     | 0,9985        | 0,9975        | 0,9966        |
| <b>13</b>     | 0,9991        | 0,9968        | 0,9976        |
| <b>14</b>     | 0,9966        | 0,9963        | 0,9965        |
| <b>15</b>     | -             | 0,9971        | -             |
| <b>Průměr</b> | <b>0,9973</b> | <b>0,9970</b> | <b>0,9969</b> |


**Tab. č. 21:** Hodnoty SSIM u pacienta č.3

V tabulkách č. 19 až 21 jsou zpracovány hodnoty SSIM pro všechny jednotlivé obrazy rozdělené dle data pořízení MR dat. Tyto tabulky jsou uvedeny pro všechny pacienty.

Čím blíží se výsledná hodnota blíží 1 tím větší strukturální podoba mezi nimi je. Ve všech tabulkách je dole uvedena hodnota průměru, která je vypočítána ze všech obrazů u jednoho vyšetření.

Sloupce určují hodnoty pro jednotlivé obrazy, rozdělené dle data. Řádky jsou očíslovány a značí pořadí obrazů v daném vyšetření.

Hodnoty jsou u všech datasetů vyšší než 0,99, tudíž je zde vysoká strukturální podobnost.



**Obr. č. 62:** Příklad grafu znázorňující SSIM pro dané obrazy u jednoho vyšetření u pacienta č. 2 [zdroj vlastní]

Obrázek 62 ukazuje názorný příklad grafického rozložení hodnot SSIM, u pacienta č. 2. Červené křížky znázorňují hodnoty strukturální podobnosti pro každý obraz. Strukturální podobnost nabývá v případě tohoto vyšetření hodnot větší než 0,99.

### Vyhodnocení evaluace

Tato kapitola porovnává kvality u automatické segmentace vůči zlatému standardu, vytvořeného manuální segmentací. Je to důležité pro zhodnocení úspěšnosti této metody a ověření správného nastavení parametrů.

Oba tyto parametry jsou normované, jsou v normalizovaných intervalech 0 až 1, kde 0 značí žádná korelace a žádná podobnost a 1 značí 100 % podobnost a korelaci. Čím blíží je výsledná hodnota 1 tím větší je shoda mezi výsledky manuální a automatické segmentace.

U pacienta č. 1 byly průměrné hodnoty indexu korelace 0,7787 až 0,8341 a průměrné hodnoty SSIM 0,9940 až 0,9975.

U pacienta č. 2 byly průměrné hodnoty indexu korelace 0,7731 až 0,8837 a průměrné hodnoty SSIM 0,9962 až 0,9970.


U pacienta č. 3 byly průměrné hodnoty indexu korelace 0,8116 až 0,8727 a průměrné hodnoty SSIM 0,9969 až 0,9973.

Největší shoda automatického segmentačního modelu aktivních kontur a zlatého standardu byla u pacienta č. 3. To by mohlo být ovlivněno různými faktory, ale největší podíl na úspěšnosti segmentačního modelu má pravděpodobně místo výskytu tumoru.


Pacienti č. 1 a 2 měli tumor uložený blízko venózních splavů, které nabývají jasu blízkého jasu tumoru. Tudíž může být segmentace tímto falešně ovlivněna. Naproti tomu pacient č. 3 měl tumor uložený blízko lebky, která má jas nižší než tumor a tím dochází k přesnější evoluci křivky.

V následujících grafech na obrázcích 63 a 64 jsou znázorněny průměrné hodnoty, každého vyšetření indexu korelace a strukturální podobnosti, rozdělené dle pacientů.

Na svislé ose jsou zobrazené hodnoty indexu korelace a SSIM. Na vodorovné ose jsou pacienti rozdělení a každý má přiřazené sloupce udávající průměrné hodnoty daných vyšetření od prvního prodělaného až k poslednímu.



**Obr. č. 63:** Graf znázorňující index korelace pro jednotlivé vyšetření [zdroj vlastní]



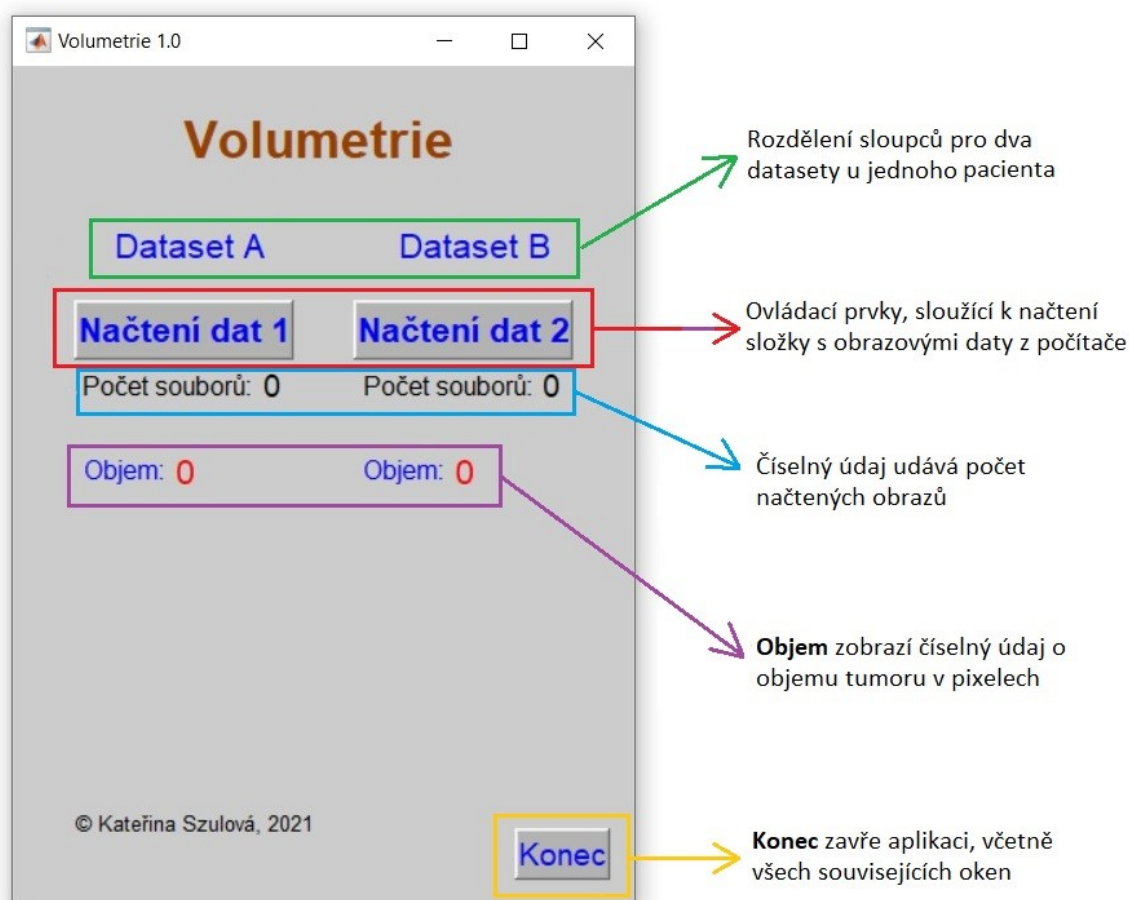
**Obr. č. 64:** Graf znázorňující index strukturální podobnosti pro jednotlivé vyšetření [zdroj vlastní]

## 2.3 Software pro automatickou detekci a kvantifikaci mozkových nádorů

Součástí diplomové práce tvoří grafické uživatelské prostředí pro automatické modelování mozkových lézí a jeho volumetrie. Software byl navržen jednoduše a intuitivně, aby byly rychle vidět výsledky, a to jsou objemy dvou datasetů jednoho pacienta, které můžeme mezi sebou porovnat.

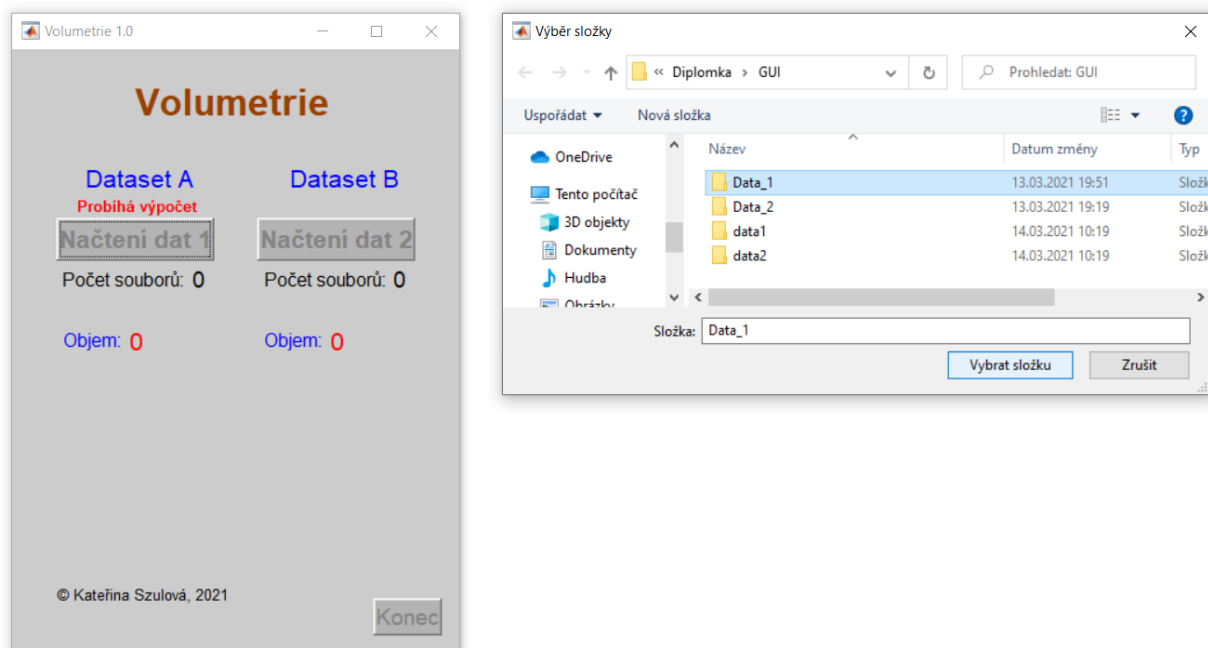
Uživatelské prostředí je vytvořeno proto, aby segmentační metodu mohli využít lékaři a zdravotničtí pracovníci bez nutnosti znalostí programu Matlab. SW slouží k segmentaci tumoru a následné volumetrii z MR obrazových dat, uložených ve složce počítače.

Vytvořený segmentační model je skryt za tlačítka Načtení dat 1 a Načtení dat 2, kde probíhá jak načtení dat pacientů, tak předzpracování, uložení do vícerozměrné matice, vizualizace prvního obrazu z datasetu a zde se také provádí vložení inicializační kontury. Automaticky proběhne celá segmentace včetně převodu na binární obraz. Výsledek volumetrie se poté zobrazí u kolonky objem. Během probíhání segmentace, již od fáze vybírání datového souboru, jsou všechna tlačítka vypnuta, aby nedošlo například k opětovnému zvolení již vybrané složky. Aplikace také ukáže údaj o probíhající akci, aby uživatel měl možnost zjistit, zda aplikace vykonává nějakou činnost. Pod ovládacími prvky Načtení dat 1 a Načtení dat 2, jsou zobrazené údaje o počtu souborů neboli kolik obrazů obsahuje nahraný dataset.



**Obr. č. 65:** Grafické uživatelské rozhraní [zdroj vlastní]

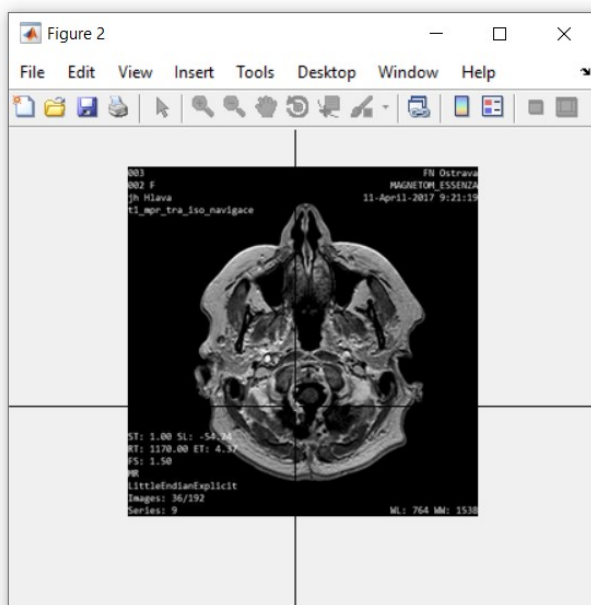
Po načtení aplikace lze vidět vytvořené rozhraní. Skrz ovládací prvek **Načtení dat 1 / Načtení dat 2**, se zvolí požadovaná složka s obrazovými daty, které mají být porovnány. Vybrány jsou dva datasety od jednoho pacienta z dvou různých časových období.



**Obr. č. 66:** Výběr požadované složky v PC [zdroj vlastní]

Na obrázku č. 66 lze vidět výběr požadované složky v počítači, u kterých bude segmentace prováděna. Během tohoto kroku jsou všechny tlačítka SW nefunkční. Nad tlačítkem **Načtení dat 1** lze vidět červený údaj o probíhající akci - **Probíhá výpočet**.

Po načtení složky se zobrazí okno s prvním MR řezem v datasetu, kde je vložena za pomoci kurzoru inicializační kontura. Vstupem uživatele se spustí na datech segmentace.



**Obr. č. 67:** Vložení inicializační kontury [zdroj vlastní]

SW provede segmentaci, převede segmentační křivky na binární obraz a vypočítá objem v pixelech a zobrazí ji na panelu. Takto to zopakujeme i pro druhý dataset u stejného pacienta.



**Obr. č. 68:** Výsledek segmentace v uživatelském rozhraní [zdroj vlastní]

Ovládacím prvkem **Konec** se zavře celá aplikace včetně všech souvisejících oken, která byla využívána k vložení inicializační kontury.

Takto může být hned zhodnocena velikost obou tumorů a jejich hodnoty porovnat. Zároveň se může porovnat kolik obrazových dat bylo načteno neboli kolik řezů MR obsahoval tumor.

## Závěr

Hlavním cílem této diplomové práce bylo vyvinout software pro segmentaci mozkových lézí z MR dat, který by ulehčil práci lékařům v kontrole tumorů u pacientů, jejichž zdravotní stav neumožňuje jiné řešení tumorů než pouhé sledování. Tato práce lékařů je velice časově náročná a každou možnost ulehčení by lékaři přivítali.

Ve spolupráci s Onkologickou klinikou FNO, bylo získáno celkem 11 datasetů od tří různých pacientů pořízených v různých časových intervalech. Na začátku bylo specifikováno, která metoda bude použita, což bylo schváleno Onkologickou klinikou. Hlavním záměrem bylo vyvinout algoritmus, který by na základě metody s minimálním zásahem uživatele automaticky segmentoval tumor a následně u něj vypočítal objem. Jako veličinu, ve které se objem počítá, byla zvolena jednotka pixel, jelikož segmentována data nejsou zanášena do ozařovacích protokolů, ale slouží jako objektivní zhodnocení stavu tumoru, zda nastala progresse, regrese či stagnace.

Práce algoritmu byla vyvíjena tak, aby byla prováděna paralelně, tudíž aby nebylo nutné zanášet na každý MR řez novou inicializační konturu, ale aby se tato kontura přenesla z prvního označeného snímku na ostatní v datasetu a bylo sníženo množství zásahů, které musí lékař provést. Proto bylo důležité už na samém začátku nastavovat všechny hodnoty tak, aby vyhovovali všem datasetům. Algoritmus je navržen tak, aby nebylo nutné do něj zasahovat a nastavovat parametry, ale aby jen intuitivně navedl lékaře k segmentaci a kýženému výsledku a to objemu. Proto jsou nastaveny jedny hodnoty vyhovující všem datům, už od předzpracování přes nastavení velikosti a tvaru inicializační křivky až po počet iteračních kroků.

V závěru proběhla evaluace navrženého algoritmu a porovnání s manuálně segmentovány daty. Vyhodnocení efektivity segmentace byla na bázi korelačního koeficientu, kde průměrná hodnota lineární závislosti na všech datech byla 81 %. Dále bylo vyhodnocení na základě strukturální podobnosti, kde podobnost průměrně na všech datech dosahovala 99 %. Hodnoty se u jednotlivých pacientů lišily, ale na přesnou analýzu, čím byly tyto odchylky způsobeny, byl poskytnut malý datový soubor klinických dat. Nejspíš jedním s hlavních aspektů bude oblast, kde se tumor nachází.

Aplikace byla konzultována s Onkologickou klinikou a bude představena lékařům. Některé aspekty této aplikace se klinice zdají ne příliš vyhovující, zejména vyšší časová náročnost a nutnost extrahovat z celého vyšetření pouze MR řezy, kde se nachází tumor a vložit je do složky.

Nelze však vyloučit vytvoření další aplikace pro segmentaci mozkových tumorů, jako zadání diplomové práce dalším ročníkům. Zde by mohl být použit jiný segmentační algoritmus, k čemuž bude zřejmě potřeba mnohem větší datový soubor pacientů.

Návrh a implementace algoritmu byla prováděna v software MATLAB R2015a.

## Zdroje

- [1] HUDÁK, R., KACHLÍK, D. Memorix anatomie. Triton, 2015. 606 s. ISBN 978-80-7387-674-6.
- [2] ČIHÁK, R. ANATOMIE 3. Druhé, doplněné a upravené vydání. Praha: Grada, 2004. 692 s. ISBN 80-247-1132-X.
- [3] Obr. č. 1, Dostupné z: <https://eluc.kr-olomoucky.cz/verejne/lekce/238>
- [4] VYHNÁNEK, L., Radiodiagnostika. Grada. 1998. 473 s. ISBN 80-7169-240-9
- [5] SEIDL, Z., VANĚČKOVÁ, M., Magnetická rezonance hlavy, mozku a páteře. Grada. 340 s. ISBN: 80-247-1106-0
- [6] Obr. č. 2, Dostupné z: [http://fmri.mchmi.com/main\\_index.php?strana=13](http://fmri.mchmi.com/main_index.php?strana=13)
- [7] VÁLEK, V., ŽIŽKA, J.: Moderní diagnostické metody: Magnetická rezonance III. díl. 1. vydání. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví Brno, 1996. 45 s. ISBN: 80-7013-225-6
- [8] VOMÁČKA, J., NEKULA, J., KOZÁK, J.: Zobrazovací metody pro radiologické asistenty. 1. vydání. Olomouc: Univerzita Palackého v Olomouci, 2012. 160 s. ISBN 978-80-244-3126-0
- [9] Obr. č. 3, Dostupné z: [http://fmri.mchmi.com/main\\_index.php?strana=14](http://fmri.mchmi.com/main_index.php?strana=14)
- [10] SCHWARZOVÁ, V., VOMÁČKA, J.: Výpočetní tomografie a magnetická rezonance v diagnostice mozku u dospělých. Praktická radiologie. Praha: Společnost radiologických asistentů ČR, 2013, roč. 18, č. 1. ISSN 1211-5053.
- [11] Obr. č. 11, Dostupné z: <https://www.siemens-healthineers.com/en-uk/magnetic-resonance-imaging>
- [12] ČERNOCH, Z., a kol., Neuroradiologie: NUCLEUS HK, 2000, 585 s., ISBN 8090175392,
- [13] SAINI, K., DEWAL, M.L. and ROHIT, M. International journal of advanced science and technology, A Review . 2010. India. 19 p.
- [14] UMBAUGH, E., SCOTT. Digital Image Processing and Analysis with MATLAB and CVIPtools, Third Edition (3rd ed.). ISBN 9781498766074. OCLC 1016899766.
- [15] JANÁKOVÁ, Segmentace, The Computer Vision Group, Department of Control and Instrumentation, Brno University of Technology, dostupné z: [http://midas.uamt.feec.vutbr.cz/POV/Lectures/05\\_Segmentace.pdf](http://midas.uamt.feec.vutbr.cz/POV/Lectures/05_Segmentace.pdf)
- [16] Obr. č. 27, Dostupné z: region grow CHEN, Y., WANG, Z., Liver Segmentation from CT Images Based on Region Growing Method; dostupné z : <https://www.semanticscholar.org/paper/Liver-Segmentation-from-CT-Images-Based-on-Region-Chen-Wang/72eb892b0d90bcf464ff5ba0df70c5132d03312f>
- [17] Obr. č. 28, Dostupné z: [https://www.researchgate.net/figure/Implementation-of-split-merge-segmentation-Algorithm-32-Split-and-merge-1-Start\\_fig42\\_305787165](https://www.researchgate.net/figure/Implementation-of-split-merge-segmentation-Algorithm-32-Split-and-merge-1-Start_fig42_305787165)
- [18] Obr. č. 29, Dostupné z: <https://cs.wikipedia.org/wiki/K-means>



- [19] KASS, M., WITKIN, A., TERZOPOULOS, D.; Snakes: Active Contour Models; 1988; Palo Alto, USA. ISSN: 1573-1405. dostupné z: <http://www.cs.ait.ac.th/~mdailey/cvreadings/Kass-Snakes.pdf>
- [20] XU, CH., PRINCE, J.L. Gradient vector flow: A new external force for snakes. 1997. Baltimore, USA. 5 p.
- [21] CHAN, T.F., VESE, L.A. Active contours without edges. 2001. Los Angeles, USA. 12 p. ISSN: 1057-7149 dostupné z: <https://www.math.ucla.edu/~lvese/PAPERS/IEEEIP2001.pdf>
- [22] RUDIN, L., OSHER, S., FATEMI, E., Physics D, vol.60: Nonlinear total variation based noise removal algorithms. 1992. Los Angeles, USA. 9 p.
- [23] OSHER, S., SETHIAN, J.A., Journal of computer physics, vol. 79 Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton–Jacobi Formulation . 1988. 37 p.
- [24] <http://www.crs.cz/cs/vyukove-materialy/technika-vysetreni/mr-protokoly-neuro.html?fbclid=IwAR0vSH5oKxyTL4AWvOM5GwvM9vLYL8zsOiiWJj2PWLxVaZvoqADQdmoGib4>
- [25] Obr. č. 23 a 24, Dostupné z: <https://slideplayer.com/slide/9047661/>
- [26] SREERANGAPPA, M., SURESH, M., JAYADEVAPPA, D., The Open Biomedical Engineering Journal, 2019, India, ISSN: 1874-1207
- [27] KUBÍČEK, J., Zpracování medicínských obrazových dat. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. ISBN 978-807-2489-411.
- [28] [http://www.cs.vsb.cz/licev/lzs%20I\\_cviceni/Cv\\_3\\_jas\\_transformace.pdf](http://www.cs.vsb.cz/licev/lzs%20I_cviceni/Cv_3_jas_transformace.pdf)
- [29] WANG, L.L., HE, A., MISHRA, C.L., Active contours driven by local Gaussian distribution fitting energy. Signal Processing [online]. 2009, 89(12), 2435-2447 [cit. 2017-03-02]. DOI: 10.1016/j.sigpro.2009.03.014. ISSN 01651684. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165168409000942>
- [30] VICIANOVÁ, V., *Extrakce objektů z medicínských obrazů na základě metody aktivních kontur*. Ostrava, 2017. Bakalářská práce. VŠB – Technická univerzita Ostrava.
- [31] Korelace. *Univerzita Palackého v Olomouci* [online]. 2011 [cit. 2018-04-12]. Dostupné z: <http://ach.upol.cz/user-files/intranet/15-korelace-2011-1321473930.pdf>
- [32] WANG, Z.; SIMONSELLI, E.P.; BOVIK, A.C. (2003-11-01). Multiscale structural similarity for image quality assessment. Conference Record of the Thirty-Seventh Asilomar Conference on Signals, Systems and Computers, 2004.
- [33] Obr. č. 48, Dostupné z: <https://www.dopocitej.cz/elipsa.html>